

2022-07

# Diseño y análisis de métodos de interrogación de un sensor de fibra óptica basado en rejillas de Bragg74 H.

San Martín Almonacid, Sebastián Esteban

---

<https://hdl.handle.net/11673/54131>

*Repositorio Digital USM, UNIVERSIDAD TECNICA FEDERICO SANTA MARIA*



UNIVERSIDAD TECNICA  
FEDERICO SANTA MARIA

DEPARTAMENTO DE ELECTRÓNICA

# Diseño y análisis de métodos de interrogación de un sensor de fibra óptica basado en rejillas de Bragg

Memoria de titulación para optar al título de  
**Ingeniero Civil Electrónico**

**Autor:**  
Sebastián San Martín A.

**Profesor guía:**  
Dr. Marcelo Soto H.

Julio - 2022

# Agradecimientos

Quisiera agradecer a mis padres y a toda mi familia por el incondicional apoyo y cariño que me han brindado a lo largo de estos años de estudio. Gracias a mi compañera por ser un pilar en todo momento. Gracias a todos mis amigos y compañeros de universidad, quienes también han sido parte de mi crecimiento durante estos años.

Gracias a mi profesor guía, Marcelo Soto, por su paciencia y enseñanzas. Quisiera agradecer también a los proyectos que hicieron posible la realización de este trabajo:

- FONDEQUIP EQM180226, Conicyt.
- FONDECYT Regular 1200299, ANID.
- FONDECYT Regular 1211980, ANID.
- Basal FB008, ANID.

# Diseño y análisis de métodos de interrogación de un sensor de fibra óptica basado en rejillas de Bragg

Sebastián Esteban San Martín Almonacid

Memoria para Optar al Título de Ingeniero Civil Electrónico

Universidad Técnica Federico Santa María

Profesor guía: Dr. Marcelo Soto H.

Julio 2022

## Resumen

En este trabajo se estudia el uso de diferentes algoritmos en la detección de temperaturas y longitudes de onda de Bragg a partir de reflexiones espectrales generadas por rejillas de Bragg inscritas en una fibra óptica. El desempeño de estos algoritmos es comparado bajo diferentes parámetros, tales como atenuación, ruido, tasa de muestreo espectral y paso de entrenamiento.

El principal algoritmo a estudiar es el GPR (Gaussian Process Regression), el cual es capaz de realizar un mapeo directo entre una forma espectral y una temperatura, a través de un proceso de entrenamiento para el cual se utilizan datos recolectados de forma experimental. Además, se propone el uso de un esquema alternativo de entrenamiento realizando un desplazamiento digital de una muestra espectral arbitraria, con el objetivo de agilizar el proceso de entrenamiento de este algoritmo.

Finalmente, se estudia la factibilidad del uso de sensores FBG en el contexto de liofilización de alimentos, lo cual puede traer grandes beneficios a este procedimiento, sobre todo debido a la capacidad de multiplexación en longitud de onda que tienen estos sensores.

**Palabras clave:** Fibra óptica, sensores FBG, Gaussian Process Regression.

# Design and analysis of interrogation methods of a fiber optic sensor based on Bragg gratings

Sebastián Esteban San Martín Almonacid

Final project report for the degree of Civil Electronic Engineer

Universidad Técnica Federico Santa María

Professor: Marcelo Soto H., PhD.

July 2022

## Abstract

In this work the use of different algorithms in the detection of temperatures and Bragg wavelengths from spectral reflections generated by Bragg gratings inscribed in an optical fiber is studied. The performance of these algorithms is compared under different parameters, such as attenuation, noise, spectral sampling rate and training step.

The main algorithm studied is the GPR (Gaussian Process Regression), which is able to perform a direct mapping between a spectral shape and a temperature, through a training process using experimentally collected data. In addition, the use of an alternative training scheme performing a digital displacement of an arbitrary spectral sample is proposed, in order to facilitate the training process of this algorithm.

Finally, the feasibility of the use of FBG sensors in the context of food freeze-drying is studied, which can bring great benefits to this procedure, especially due to the wavelength multiplexing capacity of these sensors.

**Keywords:** Optical fiber, FBG sensors, Gaussian Process Regression.

# Índice general

<b>1</b>	<b>Introducción</b>	<b>9</b>
1.1	Motivación . . . . .	9
1.2	Objetivos . . . . .	10
1.3	Estructura . . . . .	11
<b>2</b>	<b>Marco teórico</b>	<b>12</b>
2.1	Fundamentos de las rejillas de Bragg . . . . .	12
2.1.1	Principios operacionales . . . . .	12
2.1.2	Simulación de una FBG . . . . .	13
2.1.3	FBGs como sensores ópticos . . . . .	14
2.1.4	Tipos de FBGs . . . . .	15
2.1.5	Proceso de inscripción de FBGs . . . . .	17
2.1.6	Interrogación de FBGs . . . . .	19
2.2	Algoritmos de detección de peaks . . . . .	20
2.2.1	Métodos directos . . . . .	21
2.2.2	Métodos por ajuste de curvas . . . . .	22
2.2.3	Métodos basados en correlación . . . . .	23
2.2.4	Métodos basados en transformaciones . . . . .	24
2.2.5	Métodos basados en optimización (Machine Learning) . . . . .	25
2.2.6	Comparación y selección de algoritmos . . . . .	27
<b>3</b>	<b>Análisis e implementación de algoritmo GPR</b>	<b>30</b>
3.1	Detalles sobre implementación y datos utilizados . . . . .	30
3.1.1	Implementación del algoritmo . . . . .	30
3.1.2	Datos experimentales . . . . .	31
3.1.3	Datos generados digitalmente . . . . .	38
3.2	Análisis y resultados . . . . .	39
3.2.1	Metodología de análisis . . . . .	39
3.2.2	Resultados . . . . .	40
3.2.3	Análisis . . . . .	47
<b>4</b>	<b>Implementación y comparación de desempeño de algoritmos clásicos y GPR</b>	<b>49</b>
4.1	Detalles sobre implementación de algoritmos y simulación de datos . . . . .	49
4.1.1	Datos simulados . . . . .	52
4.2	Análisis de error de métodos de detección de ubicación del peak espectral . . . . .	54

---

4.2.1	Resultados con datos simulados . . . . .	54
4.2.2	Resultados con datos experimentales . . . . .	56
4.2.3	Comparación de desempeño de los algoritmos . . . . .	58
<b>5</b>	<b>Aplicación de sensores FBG en proceso de liofilización de alimentos</b>	<b>59</b>
5.1	Calibración de sensores FBG . . . . .	60
5.1.1	Fundamentos y consideraciones . . . . .	60
5.1.2	Proceso de calibración . . . . .	62
5.2	Mediciones realizadas en proceso de liofilización . . . . .	65
<b>6</b>	<b>Conclusiones</b>	<b>69</b>
6.1	Trabajos futuros . . . . .	70

# Índice de figuras

2.1	Esquema de una FBG uniforme [1]. . . . .	13
2.2	Reflectividad espectral típica de una FBG uniforme con $\lambda_B = 1550 \text{ nm}$ . . . . .	14
2.3	Reflectividad espectral de un FBG con variación de sus parámetros $L = 1, 2, 4$ cm y $kL = 0.5, 1, 2, 3$ . . . . .	14
2.4	Esquema de un FBG chirpeado [1]. . . . .	16
2.5	Reflectividad espectral de FBG <i>chirpeado</i> [1]. . . . .	16
2.6	Variación del índice de refracción de un FBG apodizado [1]. . . . .	17
2.7	Inscripción con interferómetro [1]. . . . .	19
2.8	Inscripción con phase-mask [1]. . . . .	19
2.9	Inscripción point-by-point [1]. . . . .	19
2.10	Esquema de interrogación basado en luz blanca [2]. . . . .	20
2.11	Esquema de interrogación basado en barrido de luz [2]. . . . .	20
2.12	Detección de peak con algoritmo X-dB bandwidth [2]. . . . .	22
2.13	Detección de peak con método del centroide [2]. . . . .	22
2.14	Detección de peak con ajuste polinomial de segundo orden [2]. . . . .	23
2.15	Detección de peak con método WSMC. (a) Espectro desplazado y de referencia. (b) Resultado de la correlación espectral según la ecuación 2.11 [2]. . . . .	24
2.16	Curva generada por autovalores con algoritmo KLT, para muestreos espectrales de 78 pm y 156 pm [2]. . . . .	25
2.17	Esquema básico de regresión basada en procesos gaussianos [26]. . . . .	26
3.1	Esquema de recolección de datos experimentales. . . . .	32
3.3	Reflectividades espectrales medidas en (a) escala logarítmica y (b) escala lineal. . . . .	33
3.2	Software <i>Enlight</i> utilizado para registrar las reflexiones espectrales de las FBGs. En este caso se muestran las reflexiones espectrales de dos arreglos de 10 FBGs cada uno. . . . .	33
3.4	Desplazamiento del espectro FBG al aumentar la temperatura. . . . .	34
3.5	Variación de temperatura y longitud de onda de Bragg del conjunto de entrenamiento, también se muestran los límites de estos conjuntos, junto con la variación total de temperatura y longitud de onda. . . . .	35
3.6	Evolución de (a) longitud de onda y (b) temperatura de las diferentes mediciones realizadas con distintos valores de atenuación que conforman el conjunto de datos utilizados para testear el desempeño del algoritmo GPR. . . . .	36
3.7	Reflectividades espectrales de FBG para diferentes niveles de atenuación, en (a) escala logarítmica y (b) escala lineal. . . . .	36
3.8	Resultado de submuestrear el espectro FBG medido. . . . .	37

3.9	Resultado del <i>downsampling</i> con diferentes corrimientos espectrales. . . . .	38
3.10	Desplazamiento digital de espectros FBG, en (a) escala logarítmica y (b) escala lineal. . . . .	39
3.11	Variación de la longitud de onda de Bragg en una medición de testeo. . . . .	40
3.12	Predicción GPR con intervalos de confianza. . . . .	41
3.13	Resultados de (a) <i>offset</i> RMS e (b) incertidumbre vs atenuación con datos experimentales y digitales. . . . .	42
3.14	Resultados de (a) <i>offset</i> RMS e (b) incertidumbre vs atenuación con datos experimentales y digitales, entrenados con 27 dB de atenuación. . . . .	43
3.15	Predicción de temperatura vs temperatura de referencia con datos experimentales y digitales, para una atenuación de (a) 0 dB y (b) 27 dB. . . . .	44
3.16	Predicción de temperatura vs temperatura de referencia, con datos experimentales y virtuales para un entrenamiento en menor rango de temperatura. . . . .	44
3.17	Resultados de offset vs temperatura con datos experimentales y digitales para atenuaciones de (a) 0 dB y (b) 27 dB. . . . .	45
3.18	Resultados de offset vs temperatura con datos experimentales y digitales para un entrenamiento en menor rango de temperatura . . . . .	45
3.19	Resultados de (a) <i>offset</i> RMS y (b) incertidumbre vs paso de temperatura de entrenamiento con datos experimentales y digitales. . . . .	46
3.20	Resultados de (a) <i>offset</i> RMS y (b) incertidumbre vs cantidad de puntos en peak con datos experimentales y virtuales . . . . .	47
4.1	Ejemplo de funcionamiento y resultado del centroide. . . . .	51
4.2	Ejemplo de funcionamiento y resultado del ajuste polinomial. . . . .	52
4.3	Ejemplo de algunos de los espectros FBG utilizados para el entrenamiento del algoritmo. . . . .	53
4.4	Simulaciones de espectros FBG con (a) diferentes valores de SNR = 15, 20, 60 dB y (b) diferentes tasas de muestreo ( $T_m$ ) = 10, 40, 100 pm. . . . .	54
4.5	Resultados de (a) <i>offset</i> RMS y (b) incertidumbre vs SNR con datos simulados, utilizando un muestreo de 10 pm. . . . .	55
4.6	Resultados de (a) <i>offset</i> RMS y (b) incertidumbre vs muestreo espectral con datos simulados, sin ruido agregado. . . . .	56
4.7	Resultados de (a) <i>offset</i> RMS y (b) incertidumbre vs atenuación con datos reales. . . . .	57
4.8	Resultados de (a) <i>offset</i> RMS y (b) incertidumbre vs puntos en la zona del peak con datos reales. . . . .	58
5.1	Esquema de medición en altas temperaturas . . . . .	61
5.2	Esquema de medición en bajas temperaturas. . . . .	61
5.3	Temperaturas y longitudes de onda de Bragg medidas en el rango completo de temperaturas. . . . .	62
5.4	Temperatura vs longitud de onda y curva lineal (afín) ajustada por nueva calibración. . . . .	63
5.5	Temperatura vs longitud de onda y curva cuadrática ajustada. . . . .	63
5.6	Datos de temperatura vs longitud de onda y curva ajustada de calibración original. . . . .	64

---

5.7	Comparación entre las temperaturas calculadas con la calibración de fábrica y la calibración experimental, junto con la temperatura de referencia. . . . .	65
5.8	Esquema de medición en liofilizador. . . . .	66
5.9	Reflexión espectral generada por el arreglo de FBGs utilizado. . . . .	66
5.10	Evolución de la temperatura del proceso de liofilización, registrada con un arreglo de FBGs y 3 termocuplas situadas en diferentes posiciones espaciales. . . . .	67
5.11	Evolución de la temperatura del proceso de liofilización, mostrada independientemente para cada termocupla acompañada por las temperaturas registradas por las FBGs situadas lo más cerca posible. (a) Termocupla 1 - FBG1, (b) Termocupla 2 - FBG3, (c) Termocupla 3 - FBG8. . . . .	68

# Capítulo 1

## Introducción

### 1.1 Motivación

La **fibra óptica** es reconocida en el campo de las telecomunicaciones gracias a su gran capacidad de transmisión, robustez, fiabilidad y bajo costo de fabricación, cualidades que le permiten transmitir enormes cantidades de información a través largas distancias. Desde los años 70 se ha avanzado bastante en el desarrollo de tecnologías asociadas a su uso en comunicaciones, sin embargo, la utilidad de la fibra óptica no solo se remite a esta área, sino que también destaca su empleo en sistemas de sensado óptico. Existen varios tipos de sensores ópticos, generalmente basados en algunos efectos presentes en la fibra óptica, tales como la retro-dispersión Rayleigh, Raman o Brillouin. En este trabajo de memoria se analizarán y utilizarán sensores ópticos basados en rejillas de Bragg (**FBG: Fiber Bragg Gratings**). Estos sensores son de tipo puntual (siendo también posible emplearlos de forma semi-distribuida) y destacan como unos de los más utilizados en el mercado debido a su gran precisión, robustez y velocidad de medición.

Desde su invención las FBGs han sido utilizadas en gran cantidad de aplicaciones tanto en comunicaciones como en sensores. En el área de las comunicaciones destaca su uso como precisos filtros pasa-banda o tipo notch, lo que resulta muy útil en la construcción de sistemas de multiplexado óptico. Con algunas modificaciones a su estructura general, las FBGs pueden funcionar como dispositivos correctores de distorsión, la cual es una común limitación en sistemas de comunicación. También pueden ser aplicadas en la fabricación de estructuras Fabry-Perot, utilizadas en láseres y amplificadores ópticos [1]. Por otro lado, los sensores basados en FBG han sido empleados en diversos campos, tales como dispositivos médicos, monitoreo de estructuras civiles, transporte aéreo, aplicaciones militares, entre otros [2]. En el marco de este trabajo también se explorará el uso de estos sensores en el proceso de liofilización de alimentos.

Una rejilla de Bragg (FBG) se genera a través de la modulación periódica del índice de refracción del núcleo de una fibra óptica [1]. Esta modulación genera una serie de reflexiones, las cuales entran en fase con algunas longitudes de onda de la luz incidente, dependiendo la periodicidad y el índice de refracción efectivo de la fibra. Esta dependencia es lo que permite utilizar las FBGs como sensores, ya que al variar ciertos parámetros se produce un cambio en el rango de longitudes de onda reflejadas. Las rejillas de Bragg deben ser añadidas a las

fibras ópticas tradicionales a través de un proceso llamado 'inscripción', el cual consiste de aplicar luz ultravioleta de alta intensidad a la fibra para generar la modulación del índice de refracción necesaria.

El uso de los sensores FBG se basa en interrogar una rejilla de Bragg con luz blanca (espectralmente plana y de gran ancho espectral) y analizar el espectro de la señal óptica reflejada. Las variaciones de temperatura o elongación/compresión (strain) en la zona de la FBG afectan a la modulación del índice de refracción a través de cambios en su periodicidad o índice efectivo, lo que a su vez genera un cambio en las longitudes de onda reflejadas por la rejilla. Este cambio o desplazamiento en longitud de onda permite conocer los cambios de temperatura o strain gracias a relaciones matemáticas conocidas a partir de un proceso de calibración. Identificar la magnitud de este desplazamiento espectral suele ser un problema común en este tipo de sensores, ya que muchas veces el espectro medido está contaminado con ruido o distorsión. Esto puede tener fuertes implicancias en la precisión, y por tanto en el desempeño del sensor.

El procedimiento más utilizado para determinar la magnitud del desplazamiento del espectro reflejado por las FBGs corresponde a encontrar y comparar la ubicación del peak de los espectros desplazado y original (medido a una temperatura y elongación de referencia). Esta comparación es suficientemente útil ya que la forma del espectro no se ve alterada al haber cambios de temperatura o strain. En este trabajo se implementan y analizan diferentes técnicas de obtención de la longitud de onda correspondiente al peak de reflexión de FBGs, cuyos rendimientos serán comparados bajo diferentes condiciones de operación, como por ejemplo, diferentes valores de atenuación, ruido o muestreo espectral. En particular, se analiza con gran detalle el desempeño del algoritmo de regresión basada en procesos gaussianos (**GPR: Gaussian Process Regression**), el cual es un novedoso método de *machine learning* capaz de detectar peaks espectrales o incluso detectar directamente la temperatura a partir de espectros de una FBG.

## 1.2 Objetivos

El objetivo general de este trabajo de memoria es diseñar, implementar y comparar diferentes algoritmos de detección de longitudes de onda correspondientes a peaks espectrales en el contexto de sensores basados en rejillas de Bragg (FBG). Los objetivos más específicos se listan a continuación:

1. Implementar de la forma más eficiente posible diversos algoritmos de detección de la longitud de onda del peak de la reflexión espectral.
2. Realizar un análisis comparativo del desempeño de los algoritmos implementados.
3. Profundizar el estudio en el funcionamiento del algoritmo GPR frente a diferentes escenarios.
4. Estudiar el proceso de calibración de sensores FBG y su uso en el contexto de liofilización de alimentos.

### 1.3 Estructura

Este documento se estructura de la siguiente manera: El capítulo 2 presenta el marco teórico en el cual se sustenta este trabajo, profundizando en el funcionamiento de los sensores FBG, su construcción y diferentes variedades, así como también en los diferentes tipos de algoritmos de detección de longitud de onda de peaks encontrados en el estado del arte. Además, se muestra una descripción de los principios matemáticos y operacionales del algoritmo GPR.

En el capítulo 3 se ahonda en el estudio del desempeño del GPR en la detección de temperatura a partir de espectros FBG, analizando su funcionamiento bajo diferentes condiciones de atenuación, muestreo espectral, esquemas de entrenamiento, etc. Se detalla también todo lo referente a la recolección de datos, consideraciones sobre la implementación del algoritmo y metodología de análisis. En el cuarto capítulo de este trabajo se compara el desempeño de este y otros algoritmo clásicos en la detección de peaks espectrales bajo diferentes configuraciones de ruido, atenuación y muestreo espectral, mostrando además la simulación de los espectros realizada para generar datos de prueba. Finalmente, el capítulo 5 explica el procedimiento de calibración de sensores FBG realizado para medir temperatura de forma correcta durante el proceso de liofilización de alimentos, además de presentar resultados de mediciones de temperatura obtenidos para esta aplicación.

# Capítulo 2

## Marco teórico

### 2.1 Fundamentos de las rejillas de Bragg

#### 2.1.1 Principios operacionales

En esta sección se describirán los principios funcionales de las FBG, junto con una breve descripción de sus diferentes tipos, funcionalidades y procesos de fabricación. Como se mencionó anteriormente, una rejilla de Bragg es una modulación periódica del índice de refracción de una fibra óptica [1]. Cada uno de los planos de esta modulación refleja algunas longitudes de onda de la luz incidente a ellos dependiendo si se cumple o no la condición de Bragg, la cual simplemente satisface la conservación de momentum y energía. La conservación de la energía implica que las frecuencias de las ondas incidentes y reflejadas son las mismas, mientras que la conservación de momentum implica que la suma del vector de onda de la onda incidente y de la FBG sea igual al vector de onda de la onda reflejada, lo que se resume en la siguiente expresión [1]:

$$\mathbf{k}_i + \mathbf{K} = \mathbf{k}_f \quad (2.1)$$

donde el vector de onda de la FBG ( $\mathbf{K}$ ) tiene una dirección normal a los planos de la modulación del índice de refracción y una magnitud igual a  $2\pi/\Lambda$ , mientras que los vectores de onda de las ondas incidente ( $\mathbf{k}_i$ ) y reflejada ( $\mathbf{k}_f$ ) tienen igual magnitud pero dirección contraria, lo que permite transformar la expresión anterior en [1, 3]:

$$\begin{aligned} 2 \left( \frac{2\pi n_{eff}}{\lambda_B} \right) &= \frac{2\pi}{\Lambda} \\ \lambda_B &= 2n_{eff}\Lambda \end{aligned} \quad (2.2)$$

donde  $n_{eff}$  es el índice de refracción efectivo de la fibra óptica,  $\Lambda$  es el periodo de la modulación del índice de refracción y  $\lambda_B$  es la longitud de onda central -en espacio libre- que refleja la rejilla de Bragg. Es importante destacar que si bien ésta es la única longitud de onda que cumple la condición de Bragg, no es la única reflejada por la rejilla, ya que como se puede ver en la figura 2.1, la luz reflejada más bien está compuesta por un rango de longitudes de onda. Esto se debe a que la reflexión se genera por un sucesivo esparcimiento de la luz ocasionado por las rejillas de Bragg, el cual entra en resonancia si se cumple la condición de Bragg ya descrita. Sin embargo, longitudes de

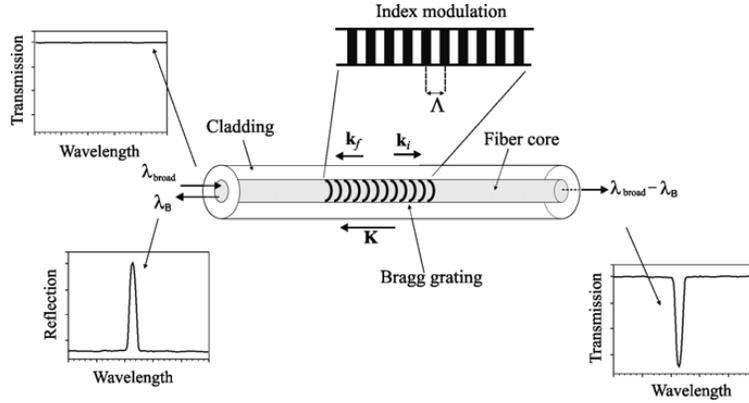


Figura 2.1: Esquema de una FBG uniforme [1].

onda cercanas a la de resonancia también presentarán un cierto grado de superposición constructiva. Por otro lado, si bien las longitudes de onda alejadas de  $\lambda_B$  producen esparcimiento en las rejillas, éstas nunca entran en fase y eventualmente se cancelan entre ellas.

### 2.1.2 Simulación de una FBG

En una FBG uniforme la teoría de modos acoplados permite obtener una expresión concisa para la reflectividad de las rejillas de Bragg [2, 3], es decir, el valor de la magnitud del espectro reflejado por estas estructuras (considerando una modulación uniforme del índice de refracción de la fibra):

$$R(\lambda) = \frac{\sinh^2(L\sqrt{k^2 - \sigma(\lambda)^2})}{\cosh^2(L\sqrt{k^2 - \sigma(\lambda)^2}) - \frac{\sigma(\lambda)^2}{k^2}} \quad (2.3)$$

donde  $R(\lambda)$  corresponde a la reflectividad de la FBG,  $\lambda$  es la longitud de onda,  $L$  es el largo total de la rejilla, y  $k$  es un número adimensional que define la 'intensidad' de la FBG, tanto en términos de su ancho de banda de media amplitud (FWHM) y del valor máximo de la reflectividad. El coeficiente  $\sigma$  se define según la siguiente expresión:

$$\sigma(\lambda) = \frac{\pi}{\lambda} \delta_{n_{eff}} + 2\pi n_{eff} \left( \frac{1}{\lambda} - \frac{1}{\lambda_B} \right) \quad (2.4)$$

donde  $\delta_{n_{eff}}$  es la amplitud de la modulación del índice de refracción. Cabe destacar que la máxima reflectividad estará dada cuando  $\lambda = \lambda_B$ , y evoluciona como  $R_{max} = \tanh^2(kL)$  [3]. En la figura 2.2 se muestra un espectro generado a partir de las expresiones 2.3 y 2.4, para  $n_{eff} = 1.5$ ,  $\delta_{n_{eff}} = 10^{-6}$ ,  $L = 1 \text{ cm}$ ,  $kL = 1.5$  y  $\lambda_B = 1550 \text{ nm}$ .

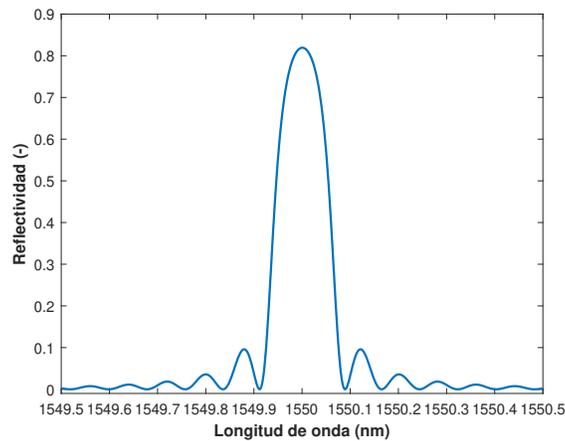


Figura 2.2: Reflectividad espectral típica de una FBG uniforme con  $\lambda_B = 1550 \text{ nm}$ .

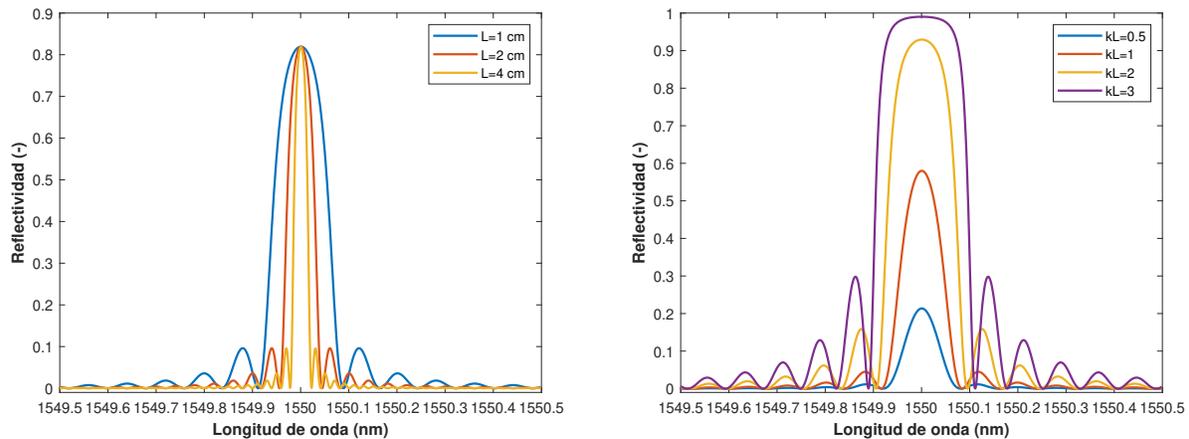


Figura 2.3: Reflectividad espectral de un FBG con variación de sus parámetros  $L = 1, 2, 4 \text{ cm}$  y  $kL = 0.5, 1, 2, 3$ .

Al variar algunos de los parámetros del FBG, la respuesta espectral de su reflexión puede presentar algunos cambios en su amplitud o ancho espectral [1, 2]. Como se puede observar en la figura, al variar el largo de la rejilla de Bragg, cambia el ancho de banda de la reflectividad espectral de la FBG. También se observa que al variar el valor del parámetro  $kL$  se genera un cambio tanto en la reflectividad máxima como en el ancho espectral de la reflectividad del FBG.

### 2.1.3 FBGs como sensores ópticos

La utilidad de las FBG como sensores radica en que la longitud de onda de Bragg depende del índice de refracción efectivo y de la periodicidad de la rejilla, los cuales se pueden ver afectados por cambios en la temperatura ( $\Delta T$ ) y compresión ( $\Delta \epsilon$ ). A partir de la ecuación 2.2, la variación de la longitud de onda reflejada por la rejilla de Bragg ( $\Delta \lambda_B$ ) se puede expresar como [1, 4, 5]:

$$\Delta\lambda_B = 2 \left[ \Lambda \frac{\partial n_{eff}}{\partial \epsilon} + n_{eff} \frac{\partial \Lambda}{\partial \epsilon} \right] \Delta\epsilon + 2 \left[ \Lambda \frac{\partial n_{eff}}{\partial T} + n_{eff} \frac{\partial \Lambda}{\partial T} \right] \Delta T$$

$$\Delta\lambda_B = k_\epsilon \Delta\epsilon + k_T \Delta T \quad (2.5)$$

En esta expresión  $k_\epsilon$  y  $k_T$  denotan la sensibilidad de  $\Delta\lambda_B$  a los cambios de strain ( $\Delta\epsilon$ ) y temperatura ( $\Delta T$ ), los que tienen valores típicos cercanos a  $1 \text{ pm}/\mu\epsilon$  y  $10 \text{ pm}/^\circ\text{C}$ , respectivamente. En aplicaciones prácticas estos valores deben obtenerse a través de un proceso de calibración. Es importante destacar que cualquier variación en la longitud de onda de Bragg puede ser producto de variaciones tanto de temperatura como de strain, por lo que en aplicaciones donde solo una de estas cantidades es de interés se deben tomar precauciones para que la otra cantidad no afecte las mediciones.

#### 2.1.4 Tipos de FBGs

##### Clasificación basada en condiciones de inscripción

Las FBG pueden ser clasificadas en 4 diferentes categorías dependiendo de las condiciones en que son inscritos (variando intensidad y tiempo de exposición a luz ultravioleta), lo que también afecta a su régimen de funcionamiento y durabilidad. También existen diferencias en los tipos de láser y fibras utilizadas para crear las rejillas de Bragg. La primera categoría, llamada *Tipo I*, es la más comúnmente utilizada en aplicaciones prácticas debido a su sencillo proceso de inscripción que considera fibras ópticas normales y baja intensidad de luz ultravioleta (UV) [1, 6]. Su durabilidad es quizás su punto más débil, considerando que las rejillas pueden llegar a deshacerse a temperaturas cercanas a los  $200 \text{ }^\circ\text{C}$ . Sin embargo, su rango de temperaturas de funcionamiento entre los  $-40$  y  $80 \text{ }^\circ\text{C}$  las hace suficientemente buenos para la mayoría de aplicaciones en telecomunicaciones y de sensado. Las FBGs de *Tipo IA* presentan el menor coeficiente de sensibilidad frente a temperatura, teniendo como mayor inconveniente un largo tiempo de exposición a luz UV para lograr su inscripción en fibras con características especiales [1, 7]. Las FBGs de *Tipo IIA* también requieren de un gran periodo de exposición para ser inscritos [1, 8], pero a diferencia de las FBGs anteriores, presentan una temperatura de eliminación cercana a los  $500 \text{ }^\circ\text{C}$ , lo que las hace más estables en temperaturas más altas. Finalmente, las FBGs de *Tipo II* requieren de una alta intensidad de luz UV para ser inscritas, generando rejillas con un alto valor en el cambio de su índice de refracción [1, 9]. Estas FBG tienen la particularidad de soportar temperaturas cercanas a los  $800 \text{ }^\circ\text{C}$  por varias horas, lo que los hace útiles como sensores en condiciones extremas de temperatura.

##### Clasificación basada en la modulación del índice de refracción

Las FBGs también pueden ser clasificadas según la forma en que se produce la modulación del índice de refracción en la zona de la rejilla. Los espectros mostrados en la sección 2.1.2 corresponden a FBGs con una modulación de tipo *uniforme* del índice de refracción:  $n(z) = n_o + \delta_n \cos(2\pi z/\Lambda)$  [1], donde  $n_o$  es el índice de refracción promedio de la fibra,  $\delta_n$  es la amplitud de la modulación, y  $z$  es la posición a lo largo del eje longitudinal de la fibra.

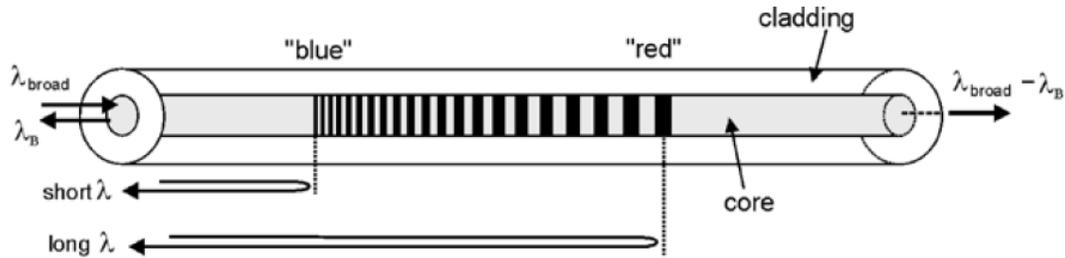


Figura 2.4: Esquema de un FBG chirpeado [1].

Es posible generar una modulación *chirpeada* del índice de refracción en la zona de la rejilla de Bragg. Esto constituye una de las estructuras basadas en FBG más interesante y utilizadas en comunicaciones ópticas, teniendo aplicaciones en compensación de dispersión y estabilización de fuentes ópticas [1]. Una modulación *chirpeada* quiere decir que su periodo varía a lo largo del eje longitudinal, generalmente en forma monótonamente creciente, como se puede ver en la figura 2.4. En este caso la expresión para longitud de onda de Bragg vista en la ecuación 2.2 pasa a tener una componente longitudinal según  $\lambda_B(z) = 2n_{eff}(z)\Lambda(z)$  [1]. De esta expresión se desprende que las secciones de la rejilla con menor periodo reflejan longitudes de onda más cortas, mientras que las partes de mayor periodo reflejan a su vez longitudes de onda más largas. Esto puede llevar a que la FBG genere una reflexión con un gran ancho de banda, lo que se puede observar en la figura 2.5, donde se muestran la reflectividades de FBGs *chirpeadas* para diferentes intensidades del *chirp*. Por lo general la variación del periodo de la modulación del índice de refracción sigue una forma lineal según  $\Lambda(z) = \Lambda_0 + \Lambda_1 z$ , donde  $\Lambda_0$  representa el periodo inicial de la modulación y  $\Lambda_1$  la intensidad del crecimiento.

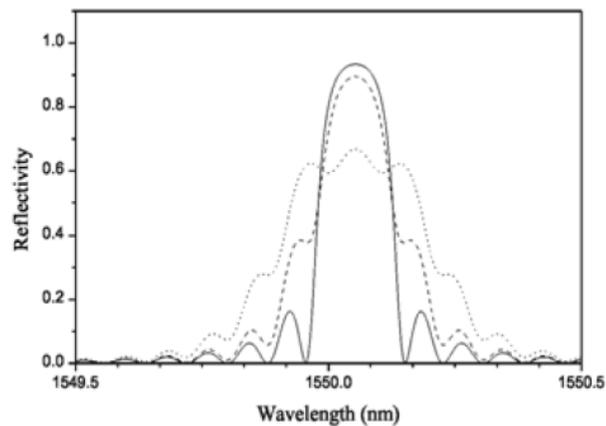


Figura 2.5: Reflectividad espectral de FBG *chirpeado* [1].

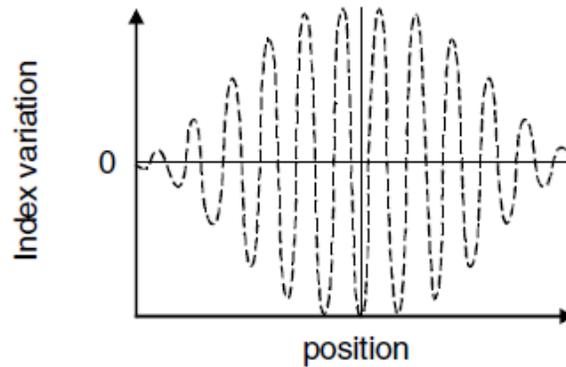


Figura 2.6: Variación del índice de refracción de un FBG apodizado [1].

Existen también FBGs cuya respuesta espectral o reflectividad no posee lóbulos laterales como los vistos en la figura 2.2 o 2.5. Este tipo de FBGs se denomina *apodizado* y son esenciales en sistemas donde la eliminación de estas bandas laterales es requerida [1]. También permiten una mejor compensación de la dispersión en FBGs *chirpeadas* [10]. En la práctica, la apodización se logra variando la amplitud de la modulación del índice de refracción en la zona de la rejilla de Bragg. Como se puede ver en la figura 2.6, en una FBG chirpeada la amplitud de la modulación varía sinusoidalmente según la ubicación longitudinal en la rejilla, mientras que en una FBG uniforme la amplitud de la modulación se mantiene constante.

### 2.1.5 Proceso de inscripción de FBGs

El proceso de inscripción de una rejilla de Bragg en una fibra óptica se refiere al procedimiento que se lleva a cabo para fabricar una FBG dentro de una fibra. Inicialmente se utilizó una técnica denominada inscripción interna [1, 11], la cual consistía en irradiar el núcleo de una fibra óptica dopada en Germanio con un láser de alta intensidad, generando un ligero cambio en su índice de refracción. Debido a que el núcleo se irradia desde solo un extremo, este tipo de FBG suele presentar una modulación no uniforme del índice de refracción, y debido al ligero cambio que induce se necesita que la rejilla sea de un largo considerable para obtener reflectividades apreciables. Debido a estas complicaciones, este tipo de inscripción ya no es utilizado, siendo reemplazado por métodos externos de inscripción, de los cuales se pueden destacar la inscripción por interferometría, el método *phase-mask* y el método *point-by-point*, que serán detallados a continuación.

La inscripción de una FBG a través de interferometría consiste en exponer la fibra (fotosensible) a rayos ultravioleta cercana a los 500 nm y así 'quemarla' y generar las variaciones en el índice de refracción. El método más común es el interferómetro divisor de amplitud [1, 12], mostrado en la figura 2.7, que consiste en una fuente de luz ultravioleta que es amplificada por un lente cilíndrico, para luego ser separada y reflejada de modo que se generen dos rayos que incidan en la fibra con el mismo ángulo, con el objetivo de generar un patrón de interferencia. En este tipo de sistemas, el periodo de la interferencia de la luz depende de la longitud de onda de la luz UV utilizada para irradiar la fibra y del ángulo con el que incide según la expresión 2.6, de la cual se desprende también la relación entre la longitud de onda de Bragg de la FBG inscrita y estos parámetros:

$$\Lambda = \frac{\lambda_{uv}}{2\sin\phi} \rightarrow \lambda_B = \frac{n_{eff}\lambda_{uv}}{\sin\phi} \quad (2.6)$$

donde  $\Lambda$  representa el periodo de la rejilla,  $\lambda_{uv}$  es la longitud de onda de la luz irradiada a la fibra y  $\phi$  corresponde a la mitad del ángulo de incidencia de esta luz con respecto a la fibra. La ventaja más importante de este tipo de inscripción es la posibilidad de fácilmente elegir la longitud de onda de Bragg deseada, lo que es posible variando por ejemplo el ángulo de incidencia [13]. Otra ventaja es que se puede variar el largo de la rejilla a inscribir, lo que permite obtener diferentes respuestas espectrales en la FBG. La principal desventaja de este método es que es muy susceptible a vibraciones mecánicas o desplazamientos microscópicos en la posición de los reflectores, lo que puede causar que los patrones de interferencia se desplacen. Además, como la luz debe viajar por considerables distancias en espacio abierto, cualquier fluctuación del aire o temperatura puede afectar al proceso de inscripción y por tanto a la calidad de la FBG fabricada. Cabe destacar también que la fuente de luz requerida para este procedimiento debe tener una excelente coherencia tanto espacial como temporal, así como también una gran estabilidad de longitud de onda y de potencia de salida.

Otro tipo de inscripción de FBG es aquel denominado *phase-mask*, que consiste en irradiar con luz ultravioleta una estructura de vidrio de sílice (phase-mask) [1, 14], cuyo objetivo es difractar la luz incidente para así crear patrones de interferencia que luego inciden en la fibra óptica foto-sensible para generar la modulación del índice de refracción. La figura 2.8 muestra este esquema de inscripción, donde se puede notar que la estructura de vidrio tiene unas pequeñas corrugaciones encargadas de generar los patrones de interferencia ya mencionados. Dichas corrugaciones pueden ser personalizadas para formar diferentes tipos de rejillas de Bragg. Este método de inscripción tiene la ventaja de simplificar el proceso ya que solo requiere de un elemento óptico (el phase-mask), lo que permite tener un proceso más robusto donde los errores provenientes de perturbaciones mecánicas son minimizados. El mayor inconveniente de este método radica en que mientras más alejado esté el phase-mask de la fibra, menor es la intensidad de la modulación de la rejilla de Bragg. Por esta razón es necesario acercarse lo más posible dicha estructura, teniendo en cuenta que la fibra puede llegar a dañarse si se acerca mucho debido a la intensidad de la radiación ultravioleta.

El último esquema de inscripción que se analizará se denomina sistema *point-by-point*, que consiste en generar cada *fringe* modulación de la rejilla de forma individual irradiando luz ultravioleta en la posición requerida [1, 15], como se puede ver en la figura 2.9. La ventaja de este método es que en teoría permite la inscripción de cualquier modulación del índice de refracción (por ejemplo apodizada), pero en la práctica es muy difícil realizar desplazamientos microscópicos de la fibra a distancias que separan cada *fringe* de la rejilla. Además, este método de fabricación es bastante sensible a perturbaciones mecánicas o de temperatura, por lo que su robustez puede catalogarse como menor que los descritos anteriormente.

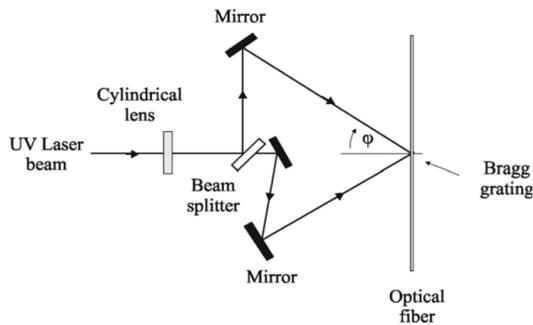


Figura 2.7: Inscripción con interferómetro [1].

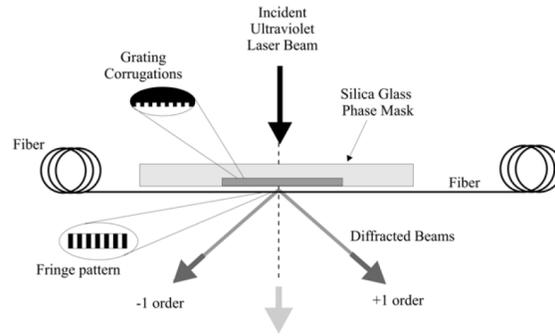


Figura 2.8: Inscripción con phase-mask [1].

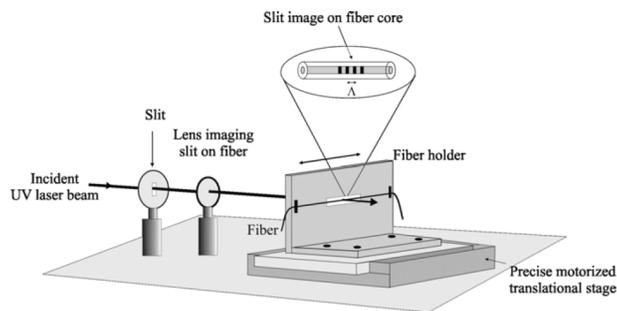


Figura 2.9: Inscripción point-by-point [1].

### 2.1.6 Interrogación de FBGs

La interrogación de una FBG puede realizarse a través de dos enfoques diferentes, dependiendo del tipo de fuente óptica que se utilice. El primer enfoque consiste en usar una fuente de luz blanca espectralmente ancha para interrogar simultáneamente un rango de longitudes de onda [2], esto generalmente se implementa utilizando un diodo emisor de luz superlumínica (SLED) o el ruido de emisión espontánea amplificada (ASE) de un amplificador de fibra dopada con erbio (EDFA). Esta luz es enviada hacia el FBG a través de un acoplador, el cual también permite que la luz reflejada por el FBG pase directamente hacia un espectrómetro, que mide la intensidad espectral de la reflexión. Es posible generar una red de sensores cuasi-distribuidos con este sistema en conjunto con un switch óptico. La figura 2.10 muestra el funcionamiento de esta red de sensores utilizando multiplexación en el dominio del tiempo y en longitud de onda.

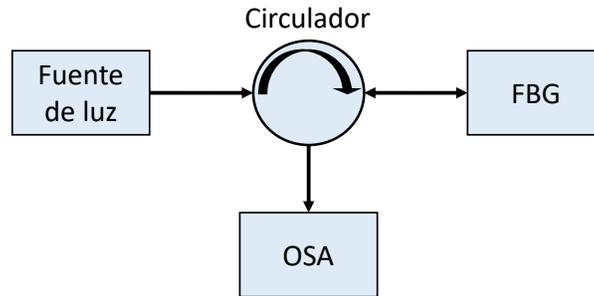


Figura 2.10: Esquema de interrogación basado en luz blanca [2].

El segundo esquema de interrogación, mostrado en la figura 2.11, se basa en un láser que varía rápidamente a lo largo de un rango de longitudes de onda [2]. La fuente de luz utilizada en este esquema es un láser ajustable de baja potencia, cuya longitud de onda es generalmente controlada por un función de tipo barrido obtenida a partir un generador de señales. Al igual que el esquema de luz blanca, este sistema puede soportar multiplexación en tiempo y en longitud de onda, esta vez utilizando solo acopladores que envían la luz reflejada por los sensores hacia un conjunto de foto-detectores y un sistema de conversión análogo-digital. La mayor ventaja de este esquema de interrogación es que posee una mayor resolución en longitud de onda que el esquema basado en interrogación por luz blanca, el cual depende de la resolución espectral dada por el espectrómetro utilizado. A pesar de esto, el sistema de luz blanca posee en general una mejor SNR y estabilidad en longitud de onda, debido a que no utiliza un láser como fuente de luz.

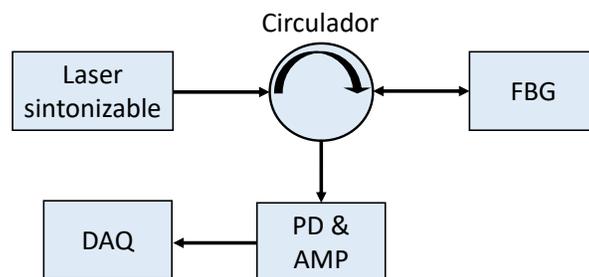


Figura 2.11: Esquema de interrogación basado en barrido de luz [2].

## 2.2 Algoritmos de detección de peaks

Existe una gran variedad de algoritmos capaces de detectar la ubicación del peak de una señal [2]. En el caso del espectro de la reflexión de una FBG, diferentes algoritmos han sido utilizados y probados para detectar la longitud de onda del peak [2]. Estos algoritmos pueden ser clasificados según el tipo de mecanismo utilizado:

- Los métodos directos obtienen la ubicación del peak directamente desde el espectro, sin realizar transformaciones o cálculos extensos.
- Los métodos por ajuste de curvas realizan un proceso de interpolación del espectro utilizando alguna función analítica, ya sea polinomial, gaussiana, splines, etc.

- Los métodos basados en correlación calculan la correlación cruzada entre el espectro medido y un espectro de referencia (obtenido en condiciones de referencia conocidas), a partir de la cual obtienen el corrimiento espectral del peak de la función de correlación.
- Existen también métodos basados en transformaciones, en los cuales el espectro es transformado a otro dominio (por ejemplo utilizando la transformada de Fourier o Karhunen-Loeve), y luego el peak puede ser encontrado en este nuevo dominio.
- Finalmente, los métodos basados en optimización de alguna función de costo permiten obtener la longitud de onda de Bragg de un espectro FBG en base a un entrenamiento realizado con diferentes mediciones previas.

A continuación se detalla el funcionamiento de algunos de estos algoritmos, comparándolos entre sí según su robustez frente a parámetros como nivel de ruido y muestreo espectral, así como también respecto a su facilidad de implementación.

Cabe destacar que algunos de estos métodos estiman la longitud de onda de Bragg ( $\lambda_B$ ) (o en otras palabras, la ubicación en longitud de onda del peak espectral) a partir del espectro de la FBG sin necesitar de ningún conocimiento previo, mientras que otros métodos requieren de un espectro de referencia para determinar el cambio en la longitud de onda de Bragg ( $\Delta\lambda_B$ ) con respecto a esta referencia. Por otro lado, otros métodos requieren de un entrenamiento previo para poder estimar  $\lambda_B$ . Para determinar el cambio de temperatura ( $\Delta T$ ) o strain ( $\Delta\epsilon$ ) lo único que se necesita es estimar el cambio en longitud de onda de Bragg ( $\Delta\lambda_B$ ), por lo que cualquiera de estos enfoques es útil en situaciones prácticas (ver ecuación. 2.5).

### 2.2.1 Métodos directos

#### X-dB bandwidth

Este método es uno de los más utilizados para la detección de peaks espectrales [16]. Consiste en establecer un umbral ( $R_{th}$ ) de X dB por debajo de la amplitud máxima del espectro medido ( $R_{max}$ ), como se muestra en la figura 2.12. Los valores del espectro que sean mayores a este umbral se considerarán como el 'espectro interno'. Finalmente se estima la longitud de onda de Bragg como la longitud de onda central de este espectro interno, lo que puede calcularse como el promedio entre las longitudes de onda inicial y final de esta sección. Este método es bastante sensible a la tasa de muestreo espectral del espectrómetro, no así a la relación señal ruido, por lo que aplicar técnicas de *resampling* puede mejorar bastante su desempeño.

#### Centroide

El método del centroide estima la longitud de onda de Bragg como el centro de masa del espectro FBG medido a partir de la expresión 2.7, donde  $n$  recorre todas las longitudes de onda muestreadas y  $R(\lambda_n)$  corresponde a la magnitud del espectro medido en la longitud de onda  $\lambda_n$  (fig. 2.13) [16, 17]. A diferencia del método X-BW, este algoritmo es sumamente sensible tanto a la cantidad de ruido presente en la señal como a la tasa de muestreo espectral de la medición. Puede resultar conveniente para el desempeño de este algoritmo recortar el espectro medido solo a su parte central. De igual manera, aplicar alguna técnica de *resampling* puede mejorar bastante su desempeño.

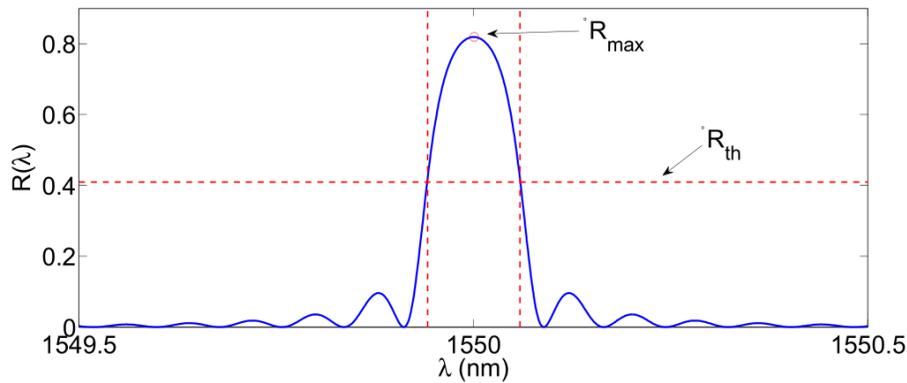


Figura 2.12: Detección de peak con algoritmo X-dB bandwidth [2].

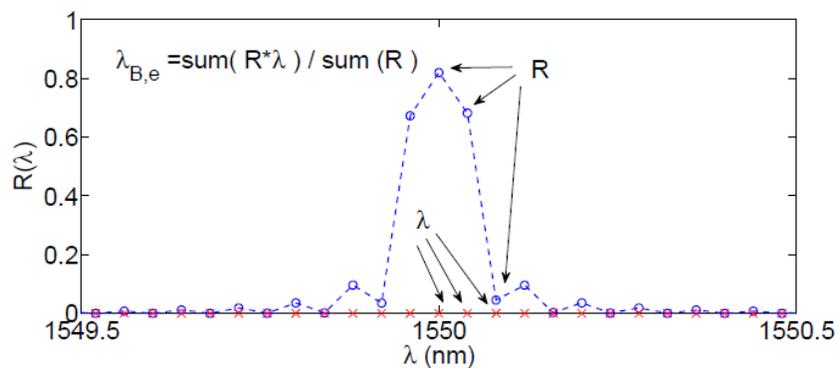


Figura 2.13: Detección de peak con método del centroide [2].

$$\lambda_B = \frac{\sum_n \lambda_n \cdot R(\lambda_n)}{\sum_n R(\lambda_n)} \quad (2.7)$$

## 2.2.2 Métodos por ajuste de curvas

### Ajuste polinomial

En el ajuste polinomial se ajustan los puntos muestreados del espectro con una expresión polinomial a través de algún tipo de regresión [16]. El ajuste de segundo orden es el más utilizado por su sencillez y fiabilidad, siendo también posible realizar ajuste con polinomios de mayor orden. El primer paso es aproximar la parte central del espectro de la FBG como una expresión polinomial cuadrática como en la ecuación 2.8 con algún tipo de regresión, como se muestra en la figura 2.14.

$$R(\lambda) \approx a_2 \lambda^2 + a_1 \lambda + a_0 \quad (2.8)$$

donde  $a_1$ ,  $a_2$  Y  $a_3$  representan las constantes de este polinomio. Una vez se hayan estimado los parámetros de la ecuación cuadrática se procede a calcular su valor máximo y por consecuencia la longitud de onda de Bragg. Esto se logra igualando la derivada de la expresión 2.8 con respecto a lambda a cero:

$$\frac{\partial R}{\partial \lambda} = 0 \rightarrow \lambda_B = -\frac{a_1}{2a_2} \quad (2.9)$$

En el caso de polinomios de mayor orden es necesario discriminar entre máximos locales y globales, por lo que puede no ser tan sencillo como lo descrito anteriormente. Este método presenta un comportamiento similar al del centroide, con una fuerte dependencia al ruido y a la cantidad de puntos del espectro.

### Ajuste gaussiano

El ajuste Gaussiano es bastante similar al polinomial excepto porque ahora al espectro medido se le ajusta una curva Gaussiana (como en la ecuación 2.10, donde  $A$ ,  $\sigma$  y  $\lambda_0$  representan los parámetros de dicha curva) en vez de a un polinomio, utilizando alguna regresión no-lineal para estimar los parámetros asociados, como por ejemplo el método de mínimos cuadrados [18].

$$R(\lambda) \approx A \cdot e^{-\frac{(\lambda-\lambda_0)^2}{2\sigma^2}} \quad (2.10)$$

A continuación se debe calcular el logaritmo de la expresión anterior para finalmente obtener una expresión cuadrática similar a la de la ecuación 2.8. Finalmente se calcula la longitud de onda de Bragg igualando la derivada a 0.

## 2.2.3 Métodos basados en correlación

### Wavelength-shifted mutual correlation

Este método calcula la correlación entre un espectro reflejado de referencia  $R_{ref}(\lambda)$  (medida a una temperatura y *strain* conocidas) y el espectro desplazado  $R(\lambda)$ , como se describe en la

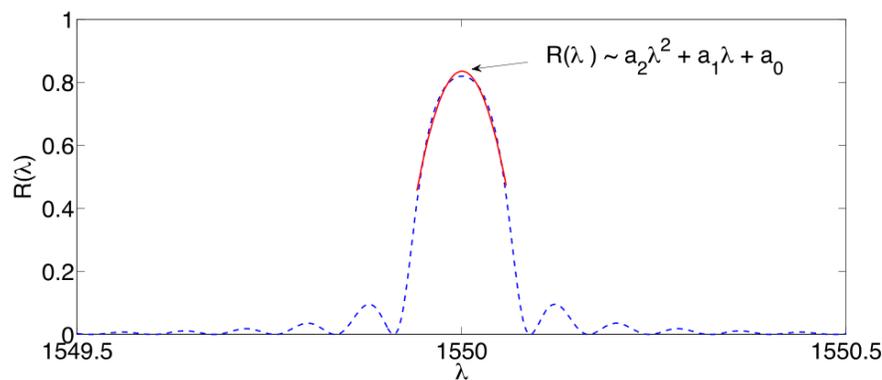


Figura 2.14: Detección de peak con ajuste polinomial de segundo orden [2].

ecuación 2.11 y se observa en la figura 2.15. Este último espectro se desplaza digitalmente en una cantidad proporcional a la tasa de muestreo espectral del espectrómetro ( $\delta\lambda$ ), repitiendo el cálculo  $m$  veces hasta encontrar el valor de desplazamiento ( $m \cdot \delta\lambda$ ) para el cual la correlación  $P_m$  se maximice, valor que correspondería a la longitud de onda de Bragg [19]. En sistemas con bajos niveles de ruido el desempeño de este método se hace independiente de dicho ruido, sin embargo, en sistemas ruidosos ( $\text{SNR} < 30$  dB) el desempeño se hace dependiente de los niveles de ruido y del muestreo espectral. Al igual que los métodos anteriores, incorporar *resampling* hace que el desempeño aumente sustancialmente.

$$P_m = \sum_{\lambda} R_{ref}(\lambda) \cdot R(\lambda - m \cdot \delta\lambda) \quad (2.11)$$

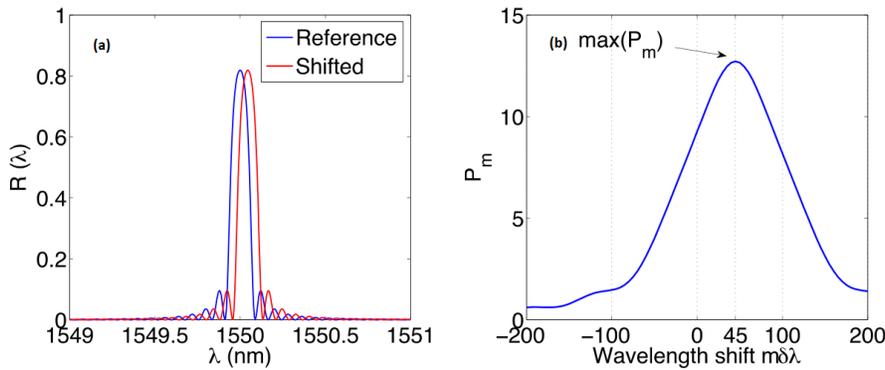


Figura 2.15: Detección de peak con método WSMC. (a) Espectro desplazado y de referencia. (b) Resultado de la correlación espectral según la ecuación 2.11 [2].

## 2.2.4 Métodos basados en transformaciones

### Fast phase correlation

El método *fast phase correlation* utiliza las fases de la transformada de Fourier de los espectros de referencia y desplazado para calcular la longitud de onda de Bragg a través de la siguiente expresión [21]:

$$\Delta\lambda_k = (\angle F[k] - \angle F_{ref}[k]) \cdot \frac{Nk}{2\pi} \delta\lambda \quad (2.12)$$

donde  $\angle F[k]$  y  $\angle F_{ref}[k]$  denotan la fase de la transformada rápida de Fourier de ambos espectros,  $N$  es la cantidad de puntos utilizada para calcular dichas transformadas, y  $\delta\lambda$  denota la tasa de muestreo espectral del espectrómetro. Si se varía el índice  $k$  para recorrer todos los puntos, se puede utilizar la mediana para obtener una medida representativa para la longitud de onda Bragg.

### Karhunen-Loeve transform

Este procedimiento se puede llevar a cabo en sistemas con muestreos espectrales muy bajos, por lo que puede ser de gran utilidad en estos escenarios [22]. El primer paso de este método

es calcular la transformada rápida de Fourier del espectro reflejado, para luego extenderla a una matrix Toeplitz  $\mathbf{M}$ . A continuación esta matrix es descompuesta en sus autovalores  $\mathbf{D}$  y autovectores  $\mathbf{V}$ , como se muestra en la ecuación 2.13:

$$\mathbf{M} = \mathbf{V} \cdot \mathbf{D} \cdot \mathbf{V}^{-1} \quad (2.13)$$

Finalmente, de la matrix de autovalores ( $\mathbf{D}$ ) se extrae el de mayor valor, a partir del cual se forman curvas en función del desplazamiento en longitud de onda, como las vistas en la figura 2.16, lo que permite obtener el desplazamiento del espectro de la FBG y por ende la cantidad física requerida utilizando alguna técnica como el centroide. Este método cobra especial relevancia en sistemas con baja tasa de muestreo espectral, siendo el de mejor desempeño en estas condiciones según [2], hasta el punto que no se necesita aplicar resampling para obtener buenos resultados.

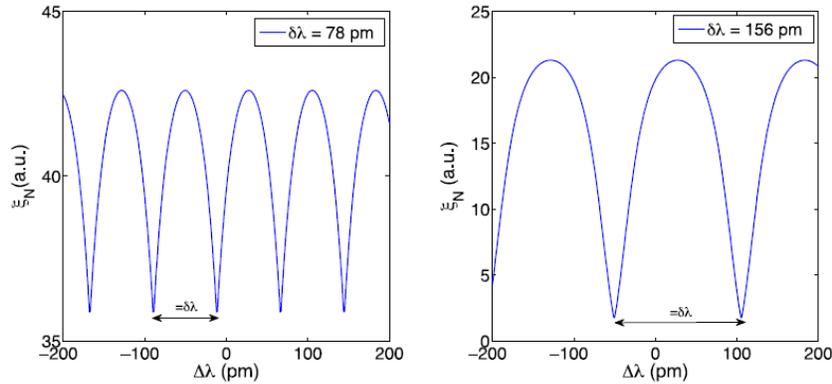


Figura 2.16: Curva generada por autovalores con algoritmo KLT, para muestreos espectrales de 78 pm y 156 pm [2].

## 2.2.5 Métodos basados en optimización (Machine Learning)

### Redes neuronales

Para estimar la longitud de onda de Bragg utilizando una red neuronal es necesario muestrear el espectro  $R(\lambda)$  en  $N$  muestras, y aproximarlos como una serie de  $P$  funciones radiales basándose en la fórmula de Gauss, descrita en la ecuación 2.15 [24]:

$$R(\lambda) \approx F(\lambda) = \omega_1 \varphi(\lambda_1) + \omega_2 \varphi(\lambda_2) + \dots + \omega_P \varphi(\lambda_P) \quad (2.14)$$

$$(2.15)$$

donde el conjunto  $[\omega_1, \omega_2, \dots, \omega_P]$  denota los pesos asociados a cada una de las  $P$  funciones descritas por  $\varphi(\lambda_p) = e^{-\frac{(\lambda-\lambda_p)^2}{2\sigma^2}}$ . Finalmente, estos pesos deben ser ajustados minimizando la función de costo mostrada en la ecuación 2.16, compuesta de la suma del error de reconstrucción y una parte de regularización (incluida para evitar problemas de sobreajuste). Una vez esta función es minimizada, la longitud de onda correspondiente al mayor peso es elegida como la longitud de onda Bragg.

$$J = \sum_{p=1}^P [F(\lambda_p) - R(\lambda_p)]^2 + \gamma \sum_{n=1}^P \omega_n^2 \quad (2.16)$$

### Gaussian Process Regression

Los procesos gaussianos son un modelo de aprendizaje supervisado utilizado ampliamente en tareas de regresión y clasificación [26]. En el caso de la regresión, el objetivo es modelar una función de la cual se tiene un conjunto de observaciones. Los métodos tradicionales de regresión suelen asignar solo una función que se ajusta a estos datos, cuando en realidad pueden haber infinitas funciones que lo hagan. La regresión basada en procesos gaussianos asigna una probabilidad a cada una de estas funciones, lo que permite conocer aquella que mejor se ajusta calculando la media de la distribución de probabilidad generada. En la figura 2.17 se muestra el proceso básico de regresión basada en procesos gaussianos, donde a partir de las observaciones o datos de entrenamiento ( $X$ : puntos rojos) y la función media estimada ( $f(X)$ : línea azul), se pueden realizar predicciones ( $f(X_*)$ ) en nuevos puntos de testeo ( $X_*$ ), con un cierto nivel de confianza dado por el área pintada en azul claro [25, 26].

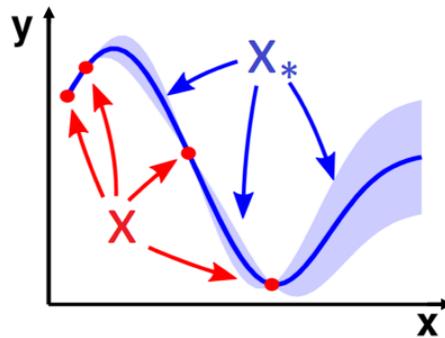


Figura 2.17: Esquema básico de regresión basada en procesos gaussianos [26].

Antes de recibir las observaciones, el modelo de regresión basado en procesos gaussianos asigna una distribución de probabilidad *a priori* a infinitas posibles funciones. Esta distribución es de tipo normal multivariable  $\mathcal{N}(\mu, k)$ , donde  $\mu$  representa la media de la distribución (generalmente 0) y  $k$  es la función de covarianza, conocida también como *kernel*, que mide el nivel de similitud entre los datos observados. Existen muchas funciones de covarianza que pueden ayudar a definir la distribución *a priori*, siendo la más común la *squared-exponential*, conocido también como *radial-basis function (RBF)* [25]:

$$k(x_i, x_j) = \theta e^{-|x_i - x_j|^2 / 2\beta^2} \quad (2.17)$$

donde  $x_i$  y  $x_j$  son dos observaciones (muestras) diferentes, mientras que  $\theta$  y  $\beta$  son parámetros del kernel que deben ser optimizados a través de un entrenamiento. Una vez se reciben las observaciones, las infinitas funciones se reducen a aquellas que se ajustan mejor a los datos, con lo que se obtiene una distribución *posterior*, correspondiente a la distribución *a priori* actualizada con los nuevos datos. A partir de esta distribución *posterior* se puede calcular

la función media  $f$  y luego las nuevas predicciones  $f(\mathbf{X}_*)$ . Para realizar las predicciones se necesitan calcular 4 diferentes matrices de covarianza utilizando el kernel  $k$  y los datos de entrenamiento  $\mathbf{X}$  y testeo  $\mathbf{X}_*$  [25]:

$$\mathbf{K} = k(\mathbf{X}, \mathbf{X}), \mathbf{K}_* = k(\mathbf{X}, \mathbf{X}_*), \mathbf{K}_*^T = k(\mathbf{X}_*, \mathbf{X}), \mathbf{K}_{**} = k(\mathbf{X}_*, \mathbf{X}_*) \quad (2.18)$$

A partir de estas matrices, las predicciones pueden ser realizadas con la ecuación 2.19, donde  $f(\mathbf{X}_*)$  corresponde a las predicciones hechas con los nuevos datos o datos de testeo,  $f(\mathbf{X})$  corresponde a los valores obtenidos por la función con los datos de entrenamiento, y  $\sigma$  es un parámetro relacionado al ruido en los datos. De igual forma se puede conocer la varianza de las predicciones con la ecuación 2.20, la cual puede ayudar a evaluar el nivel de validez de los resultados. Cabe destacar que los parámetros del kernel y relacionados al ruido deben ser optimizados a través de la minimización del error de predicción utilizando algún algoritmo como gradiente descendiente u otro [25, 26].

$$f(\mathbf{X}_*) = \mathbf{K}_*^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} f(\mathbf{X}) \quad (2.19)$$

$$cov(f(\mathbf{X}_*)) = \mathbf{K}_{**} - \mathbf{K}_*^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{K}_* \quad (2.20)$$

donde  $\mathbf{I}$  se refiere a la matriz identidad. En el caso de la detección de peaks espectrales, lo que el algoritmo GPR aprende es un mapeo directo entre la forma espectral y la correspondiente longitud de onda de Bragg, o como ha sido demostrado en [27], puede incluso aprender un mapeo entre la forma de onda y temperatura, para luego realizar predicciones con nuevos conjuntos de datos. En dicho trabajo también se compara el desempeño de este algoritmo con otros métodos clásicos, llegando a la conclusión de que el GPR entrega mejores resultados, especialmente en escenarios de bajo muestreo espectral. En [28] se estudia el desempeño del GPR y otros algoritmos basados en aprendizaje de máquinas en la medición de peso usando sensores FBG, donde se muestra que la regresión basada en procesos gaussianos es el método más efectivo en términos de precisión y tiempos de cómputo. Sin embargo, ningún trabajo revisado ha profundizado en el desempeño del algoritmo GPR en función de diferentes parámetros como ruido, atenuación o pasos de entrenamiento, ni tampoco se han estudiado esquemas de entrenamiento basados en datos generados digitalmente. En el siguiente capítulo se detalla más respecto a la implementación y uso de este algoritmo para la detección de peaks espectrales o temperaturas, profundizando también en la metodología de obtención de los conjuntos de datos y resultados. Además, se estudia el desempeño del GPR en función de los parámetros ya mencionados, así como también el alcance del esquema de entrenamiento usando datos generados digitalmente.

### 2.2.6 Comparación y selección de algoritmos

En la tabla 2.1 se muestra una comparación entre los diferentes métodos revisados anteriormente. Dentro de los criterios comparativos se encuentra la factibilidad de implementación, desempeño frente a diferentes parámetros como atenuación, ruido, muestreo espectral, novedad e interés. A partir de la información mostrada se procede a seleccionar aquellos métodos que presenten un mayor desafío y oportunidad de experimentación en diferentes configuraciones. Primero, se implementará el método del centroide por su sencilla programación, bajo procesamiento, robustez y precisión. Los resultados obtenidos a partir de

este método pueden ser utilizados posteriormente como marco de referencia para comparar los demás métodos implementados. El método de ajuste polinomial es el siguiente a implementar, seleccionado por su gran precisión y sencillez.

El principal método a implementar es la regresión basada en procesos gaussianos (GPR), para así probar el funcionamiento de esta reciente técnica en sistemas de interrogación de FBGs. Se busca estudiar el desempeño de este algoritmo frente a parámetros tales como muestreo espectral, atenuación o ruido. Se debe tomar en cuenta que los resultados obtenidos a partir de los métodos mencionados anteriormente serán utilizados como referencia para comprobar la exactitud del método GPR, y tener así un marco comparativo basado en los parámetros ya mencionados. También se estudia la factibilidad de un esquema de entrenamiento basado en datos generados digitalmente para facilitar la posible implementación de este algoritmo en sistemas de interrogación en tiempo real, principalmente gracias a la reducción de la cantidad de datos de entrenamiento necesarios.

<b>Método</b>	<b>Detalles de implementación</b>	<b>Desempeño</b>	<b>Utilidad</b>
<b>X-BW</b>	Sencilla implementación y muy bajo tiempo de procesamiento.	Robusto frente a ruido pero muy sensible al muestreo. Se debe estudiar su desempeño frente a atenuación.	Es un método bastante común y sencillo, extensamente utilizado en sistemas comerciales de interrogación.
<b>Centroide</b>	Sencilla implementación y muy bajo tiempo de procesamiento.	Es un método sensible al ruido, pero es posible aplicarlo en esquemas de bajo muestreo. Se debe estudiar su desempeño frente a atenuación.	Es un método sencillo pero puede ser utilizado como referencia para comparar el desempeño de métodos más complejos.
<b>Ajuste polinomial</b>	Su implementación se facilita gracias a la existencia de librerías. Tiene un tiempo de procesamiento considerable.	Tiene un mejor desempeño que los métodos anteriores, especialmente con bajas tasas de muestreos. Es sensible tanto al muestreo como al ruido.	Es un método eficiente y robusto, sencillamente implementable. Puede ser utilizado como referencia.
<b>Ajuste gaussiano</b>	Similar al caso polinomial.	Tiene muy buena precisión, al igual que el ajuste polinomial es sensible al ruido y muestreo.	Es un método sencillo de implementar, puede ser utilizado como referencia.
<b>Correlación</b>	Su implementación se debería facilitar considerando la existencia de funciones existentes para los cálculos necesarios. Tiene poco tiempo de procesamiento.	Tiene un peor desempeño que lo demás métodos, pero es capaz de operar con cierta eficacia en configuraciones ruidosas. Es bastante sensible a la tasa de muestreo del sistema.	Su implementación puede resultar interesante en la experimentación con configuraciones ruidosas.
<b>KLT</b>	Su implementación puede requerir optimizar los cálculos y así evitar extensos tiempos de cómputo, dependiendo del tamaño de las señales analizadas.	Presenta el mejor desempeño en sistemas de bajo muestreo, sin embargo, su precisión depende de una calibración previa.	Puede resultar interesante debido a su capacidad de trabajo en sistemas de bajo muestreo.
<b>Redes neuronales</b>	Su implementación puede resultar desafiante por la gran capacidad de computo necesaria.	El desempeño de este algoritmo se necesita testear en diferentes configuraciones.	Debido a su novedad, puede ser un desafío implementar este método, sea basado en redes neuronales artificiales o convolucionales.
<b>GPR</b>	Compleja implementación debido a cantidad de experimentación necesaria y capacidad de cómputo.	Es necesario estudiar el desempeño de este algoritmo frente a diferentes parámetros.	Debido a su novedad es interesante indagar su implementación y desempeño en la detección de peaks espectrales.

Cuadro 2.1: Comparación entre los diferentes métodos revisados

## Capítulo 3

# Análisis e implementación de algoritmo GPR

En el presente capítulo se estudia el desempeño del algoritmo GPR en el contexto de sensores FBG, profundizando en su implementación y uso en la detección de temperatura a partir de reflectividades espectrales medidas experimentalmente. Se detalla la metodología de recolección de los datos utilizados para entrenar y testear el algoritmo, así como también el procedimiento para obtener los resultados mostrados. Este análisis se lleva a cabo en función de diferentes parámetros de los datos, entre ellos su atenuación, paso de entrenamiento, temperatura y muestreo espectral. Además, se propone el uso de un esquema de entrenamiento que usa datos generados de forma digital, con el objetivo de simplificar la toma de datos y el posterior entrenamiento del algoritmo.

### 3.1 Detalles sobre implementación y datos utilizados

#### 3.1.1 Implementación del algoritmo

La implementación del algoritmo GPR, descrito en la sección 2.2.5, se lleva a cabo utilizando la función de Matlab *fitrgp*, la cual se encarga de entrenar y generar un modelo de regresión basado en procesos gaussianos a partir de los datos de entrenamiento que le son entregados. Para entrenar este algoritmo se utiliza un conjunto de datos consistente de reflectividades espectrales (*predictors*) y sus correspondientes longitudes de onda de Bragg (*labels*) [25]. Notese que estos *labels* pueden también corresponder al mapeo directo a la temperatura o *strain* de la FBG. Si bien en el marco teórico de este trabajo se examina la capacidad de los algoritmos para detectar longitudes de onda de Bragg, en este análisis se estudia el desempeño del GPR en la detección de temperatura, ya que como ha sido demostrado en [27], el algoritmo es capaz de hacer un mapeo directo entre la forma espectral entregada y la temperatura correspondiente. Cabe destacar que cada una de las reflectividades entregadas al algoritmo corresponde a un vector de  $n$  puntos espectrales, por lo que para entrenar el algoritmo con  $m$  realizaciones se le debe proporcionar una matriz  $m \times n$  de espectros y un vector  $m \times 1$  de *labels*. Se debe tener precaución al entrenar con demasiadas realizaciones, puesto que el algoritmo presenta una complejidad de  $O(n^3)$  [26], elevando considerablemente el tiempo de cómputo.

Antes de entrenar el algoritmo, los datos utilizados deben ser preprocesados. Como se describe en la sección 3.1.2, los datos pueden estar en escala logarítmica al ser medidos con un interrogador de FBG o con un analizador de espectros ópticos, lo cual puede presentar ciertos problemas en el funcionamiento del algoritmo, sobre todo debido a los cambios en la forma espectral en la zona de los lóbulos laterales o en partes cercanas al piso de ruido del instrumento de medición. Por esta razón, se decide transformar los datos a escala lineal según  $R_{lin} = 10^{R_{log}/10}$ , donde  $R_{lin}$  corresponde a las reflectividades espectrales en escala lineal y  $R_{log}$  en escala logarítmica. Luego, para evitar cualquier discrepancia entre datos de entrenamiento y testeo, se aplica una normalización (entre 0 y 1) de la amplitud de los espectros, lo que también ayuda a que el entrenamiento y las predicciones sean independientes de la amplitud de los datos a analizar. Cabe señalar que, dado que el algoritmo GPR aprende un mapeo directo entre la forma espectral y el correspondiente valor de referencia, es imperativo que tanto los espectros de entrenamiento como los de testeo estén ubicados exactamente en el mismo rango de longitudes de onda, ya que al entregarle un espectro fuera del rango entrenado, se espera que el algoritmo genere errores considerables en la estimación de de la longitud de onda de Bragg o temperatura.

En el código 3.1 se muestra la implementación básica del algoritmo GPR en Matlab, donde primero se entrena el modelo con la función *fitrgp* y luego se realizan las predicciones en base a nuevos datos con la función *predict*. La función de entrenamiento ofrece diversas opciones con las cuales se puede experimentar, entre ellas el kernel a usar, métodos de aproximación y estimación de parámetros, parámetros iniciales del modelo, tipo de optimización, etc. En este caso, el modelo es entrenado con el kernel *matern32*, debido a los buenos resultados obtenidos durante el desarrollo de este trabajo. Mayor experimentación con estas opciones puede ser parte de un trabajo futuro a realizar, idealmente buscando la configuración óptima para diferentes escenarios de atenuación, ruido o muestreo.

```

1 % R_train: Matriz de reflectividades espectrales de entrenamiento
2 % R_test: Matriz de reflectividades espectrales de testeo
3 % label_train: Vector de labels (temperaturas o longitudes de onda de Bragg)
4
5 % Train
6 gprMdl = fitrgp(R_train, label_train, 'KernelFunction', 'matern32');
7
8 % Test
9 result = predict(gprMdl, R_test);

```

Código 3.1: Implementación GPR

Cabe detallar que el GPR debe ser entrenado en un rango de *labels* (longitud de onda de Bragg o temperatura) que sea mayor o igual al rango con el que será testeado, ya que como se puede ver en la figura 2.17, al realizar predicciones en puntos que estén fuera del rango de entrenamiento la varianza del resultado aumenta considerablemente (mostrada en la figura como un área ensombrecida en la zona posterior al último punto  $X$  de entrenamiento).

### 3.1.2 Datos experimentales

Los datos experimentales son recolectados a partir del esquema presentado en la figura 3.1, consistente de un interrogador de FBGs comercial modelo *Hyperion si155*, un atenuador óptico variable (VOA: variable optical attenuator) y un sensor FBG dentro de un vaso precipitado lleno de agua dispuesto sobre un calentador. El interrogador es un equipo comercial

que utiliza un esquema de interrogación basado en un barrido de luz como el descrito en la figura 2.11. Este equipo utiliza un muestreo espectral de 10 pm, a una frecuencia máxima de interrogación de 10 Hz, y es capaz de entregar el espectro de las reflexiones en un rango de longitudes de onda de 1500 a 1600 nm, como se muestra en la figura 3.2. Cabe señalar también que el interrogador calcula y entrega los valores de la ubicación espectral de los peaks, los que junto con un proceso de calibración permiten calcular las correspondientes temperaturas que serán utilizadas como referencia para la validación y entrenamiento del algoritmo.

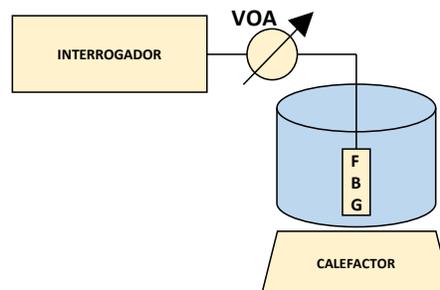


Figura 3.1: Esquema de recolección de datos experimentales.

El VOA se usa para variar la atenuación de la luz enviada a la FBG y su reflexión, con el objetivo de tomar mediciones en diferentes niveles de atenuación y comprobar así el desempeño del algoritmo GPR frente a este parámetro. El sensor FBG se sumerge en agua ya que esta puede actuar como un *buffer* térmico, lo cual ayuda a que la temperatura se mantenga más estable que si estuviera en aire. Además, utilizando el calefactor se puede aumentar la temperatura de la FBG, y así generar cambios en la longitud de onda de Bragg (desplazamientos) de los espectros. De esta manera, se obtienen conjuntos de datos en diferentes temperaturas/longitudes de onda tanto para entrenar como para testear los algoritmos. A continuación se detallan los aspectos más importantes referente a los datos experimentales recolectados, como lo son las variaciones de la atenuación y temperatura, y tamaño de los conjuntos de datos.

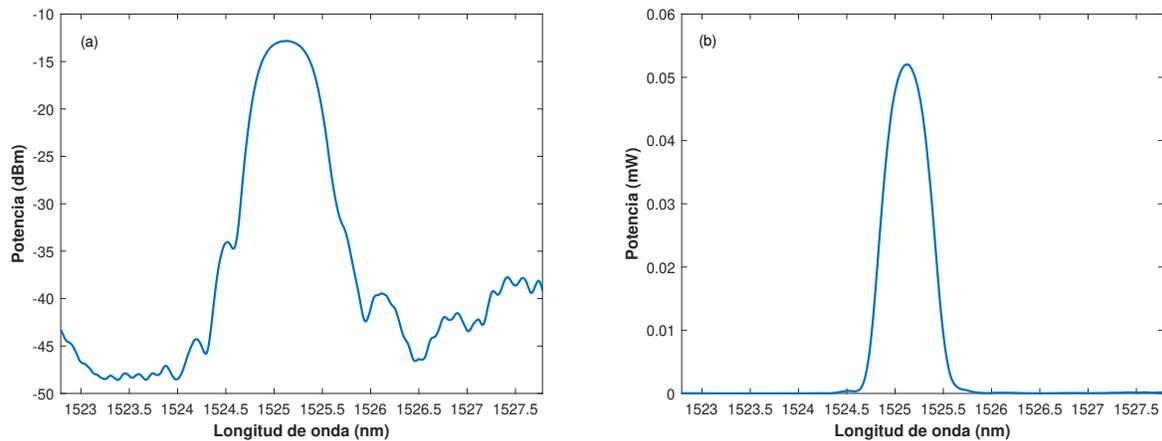


Figura 3.3: Reflectividades espectrales medidas en (a) escala logarítmica y (b) escala lineal.

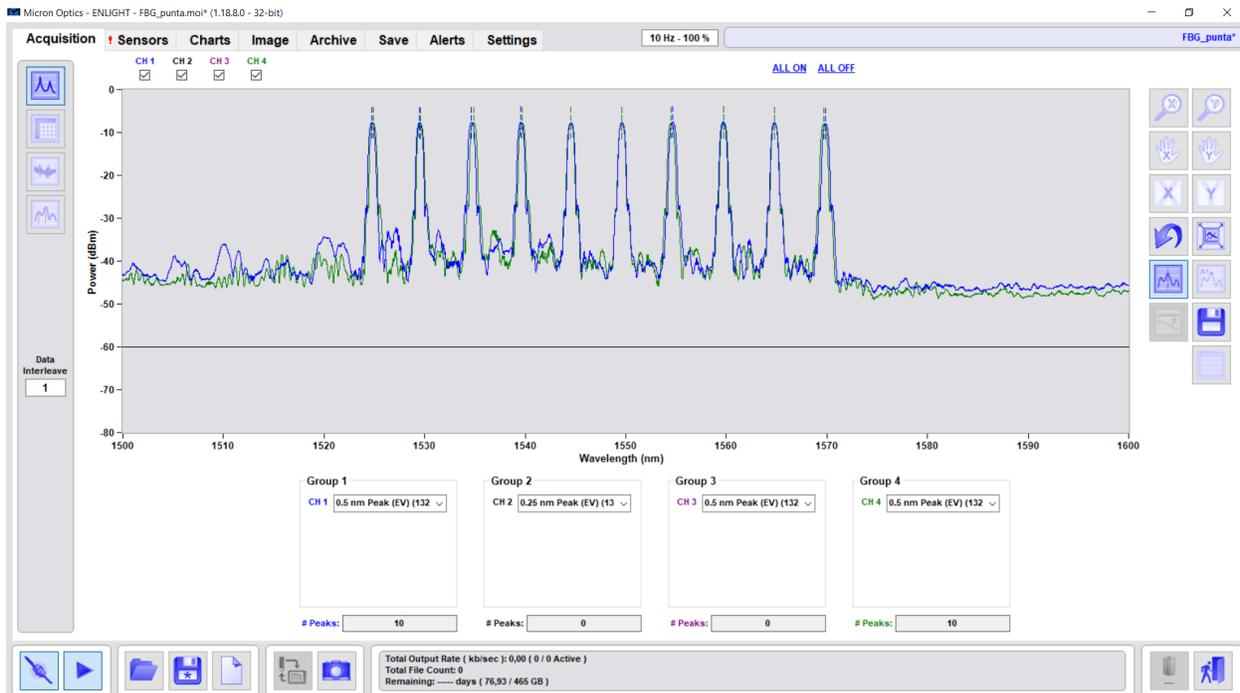


Figura 3.2: Software *Enlight* utilizado para registrar las reflexiones espectrales de las FBGs. En este caso se muestran las reflexiones espectrales de dos arreglos de 10 FBGs cada uno.

Como se mencionó, el interrogador permite registrar las reflexiones espectrales de una FBG, como se muestra en la figura 3.3-(a), correspondiente a una de las primeras reflexiones mostradas en la figura 3.2. Es importante resaltar que la amplitud del espectro medido por el interrogador se encuentra en escala logarítmica (dBm), por lo que es necesario transformarla a escala lineal (mW), obteniéndose por ejemplo el espectro mostrado en la figura 3.3-(b).

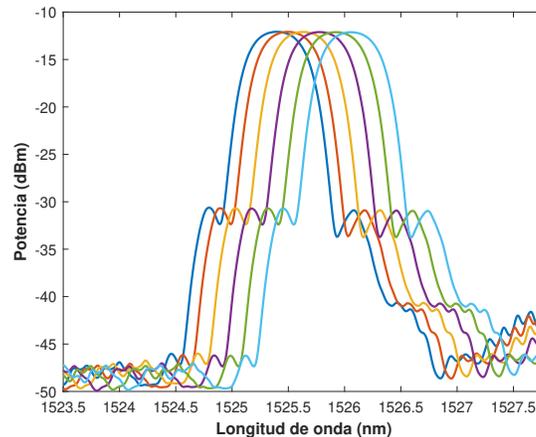


Figura 3.4: Desplazamiento del espectro FBG al aumentar la temperatura.

La figura 3.4 muestra algunos ejemplos de cómo el espectro se desplaza en longitud de onda al variar la temperatura del sistema desde temperatura ambiente ( $20^{\circ}\text{C}$ ) hasta cerca de los  $90^{\circ}\text{C}$ . Considerando que este aumento de temperatura toma cerca de 45 minutos, y que se registra correctamente un promedio de 2 o 3 realizaciones por segundo, el conjunto de datos generado tiene alrededor de 7000 realizaciones, las cuales son usadas para el entrenamiento del algoritmo. Sin embargo, no se utiliza la totalidad de dicho conjunto, sino que se seleccionan alrededor de 1000 realizaciones para entrenar el algoritmo GPR. Esta disminución del tamaño del conjunto de entrenamiento tiene como objetivo reducir el tiempo de entrenamiento del modelo, debido a que a menor número de realizaciones, menos tiempo toma este proceso.

La figura 3.5 muestra que el rango de temperaturas con el que se entrena el algoritmo equivale a una variación en longitud de onda cercana a  $0.75\text{ nm}$ , registrada originalmente a una tasa de desplazamiento espectral aproximada de  $0.1\text{ pm}$  por realización. A través del proceso de calibración (descrito a continuación), se determina que este paso corresponde a un paso en temperatura de  $0.01^{\circ}\text{C}$  (una variación de  $1^{\circ}\text{C}$  equivale a  $0.01\text{ nm}$ ). La calibración mencionada consiste de relacionar, a través de una expresión matemática de tipo cuadrática, los valores de longitud de onda entregados por el interrogador y los valores de temperatura (de referencia) registrados por una termocupla al variar la temperatura del sistema visto en la figura 3.1. Esta relación se lleva a cabo utilizando un ajuste polinomial de curvas con la función de Matlab *polyfit*, con la cual se determinan los valores de las constantes asociadas a esta expresión matemática. Este procedimiento permite conocer el valor de temperatura asociado a nuevas mediciones de longitud de onda del peak hechas con el interrogador. Más detalles respecto a los fundamentos e implementación de este proceso se muestran en el capítulo 5 de este trabajo.

Al realizar pruebas entrenando el algoritmo con diferentes pasos de temperatura se descubre que las predicciones hechas con un modelo entrenado con un paso de  $0.01^{\circ}\text{C}$  presenta un mayor nivel de error que al entrenar con, por ejemplo,  $0.07^{\circ}\text{C}$ . Esto permite concluir que entrenar con un paso de temperatura muy bajo conduce a un *overfitting* del modelo. En consecuencia, los análisis realizados en el presente capítulo son llevados a cabo con

un conjunto de entrenamiento más acotado que el recolectado originalmente, evitando el sobreajuste y excesivos tiempos de cálculo. Para obtener este subconjunto se consideran las realizaciones cuyas temperaturas de referencia se ajusten lo más posible al paso de entrenamiento, en este caso considerado como  $0.07^\circ\text{C}$ . Más detalles sobre el desempeño del GPR frente al paso de entrenamiento se muestran en la sección 3.2.2.

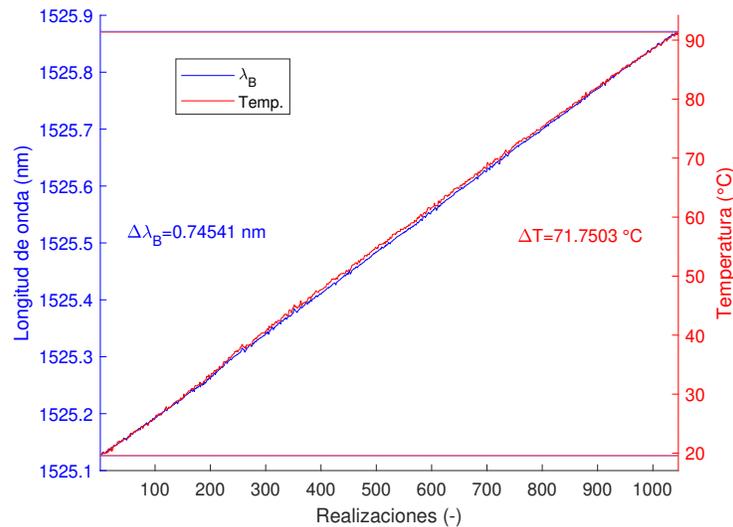


Figura 3.5: Variación de temperatura y longitud de onda de Bragg del conjunto de entrenamiento, también se muestran los límites de estos conjuntos, junto con la variación total de temperatura y longitud de onda.

Para el testeo de los algoritmos se registran datos con diferentes niveles de atenuación óptica y de una duración de 2 minutos cada una. De esta manera, cada medición tiene cerca de 550 realizaciones (en este caso se registran correctamente entre 4 y 5 realizaciones por segundo). Esta cantidad de realizaciones se considera suficiente para llevar a cabo un correcto estudio estadístico del desempeño del algoritmo. En estas mediciones se intenta mantener la temperatura lo más estable posible por un periodo de tiempo, con el objetivo de generar un conjunto de espectros cuyas longitudes de onda de Bragg se mantengan sin mayor variación, como se puede observar en la figura 3.6. Esta figura muestra las diferentes mediciones realizadas manteniendo la temperatura constante en un rango entre  $30^\circ\text{C}$  y  $45^\circ\text{C}$ , tanto para la evolución de longitud de onda como de la correspondiente temperatura (obtenida utilizando el procedimiento de calibración descrito anteriormente). Es importante destacar que el rango de temperaturas en el que se encuentran las mediciones del conjunto de testeo es menor al rango de temperaturas con las cuales se entrena el algoritmo. Además, se registran 2 mediciones independientes de larga duración (30 minutos) en las cuales la temperatura varía en un rango ligeramente menor al rango de entrenamiento ( $25\text{-}85^\circ\text{C}$ ), con el objetivo de generar 2 conjuntos de datos con los cuales probar el desempeño del algoritmo con respecto a la temperatura. Estos datos son recolectados con 2 niveles de atenuación diferente (0 dB y 27 dB) de forma tal que se pueda comparar el nivel de error en diferentes configuraciones de testeo y entrenamiento.

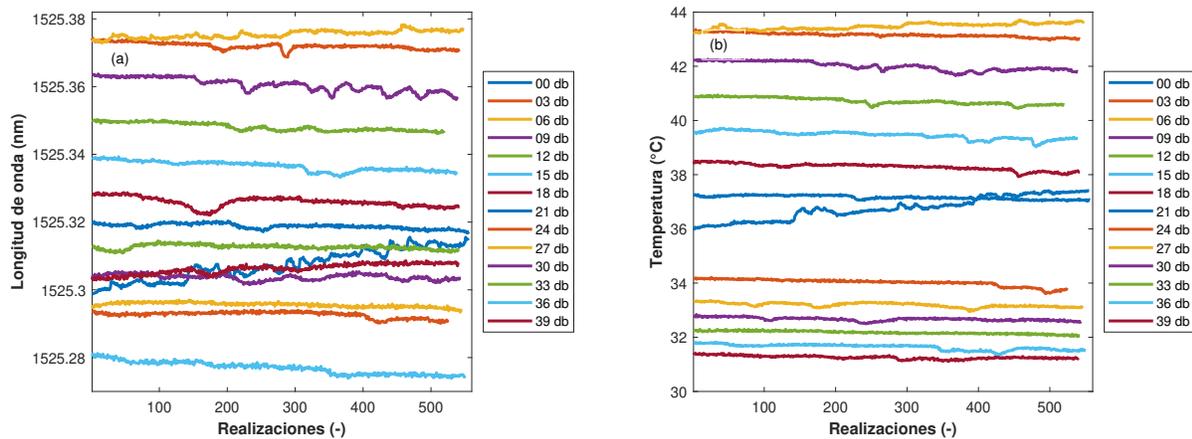


Figura 3.6: Evolución de (a) longitud de onda y (b) temperatura de las diferentes mediciones realizadas con distintos valores de atenuación que conforman el conjunto de datos utilizados para testear el desempeño del algoritmo GPR.

En la figura 3.7-(a) se muestran espectros FBG (en escala logarítmica) para diferentes niveles de atenuación, la cual va aumentando cada 3 dB desde 0 dB hasta los 39 dB. Resulta interesante como la forma espectral va perdiendo la información contenida en sus lóbulos laterales, debido a que estos se esconden entre el piso de ruido de la medición (-60 dBm). La figura 3.7-(b) muestra estos espectros pero en escala lineal y normalizados entre 0 y 1. En este caso también se puede notar como algunos lóbulos laterales se pierden entre el piso de ruido, mientras que otros se ven bastante minimizados debido a la escala utilizada. Esta figura cobra relevancia puesto que éstas son las formas espectrales que le son entregadas al algoritmo, lo que puede resultar bastante perjudicial puesto que este método es entrenado con la forma espectral del caso sin atenuación (0 dB), y dado que esta forma difiere bastante con respecto a los casos más atenuados, es de esperar que su desempeño empeore.

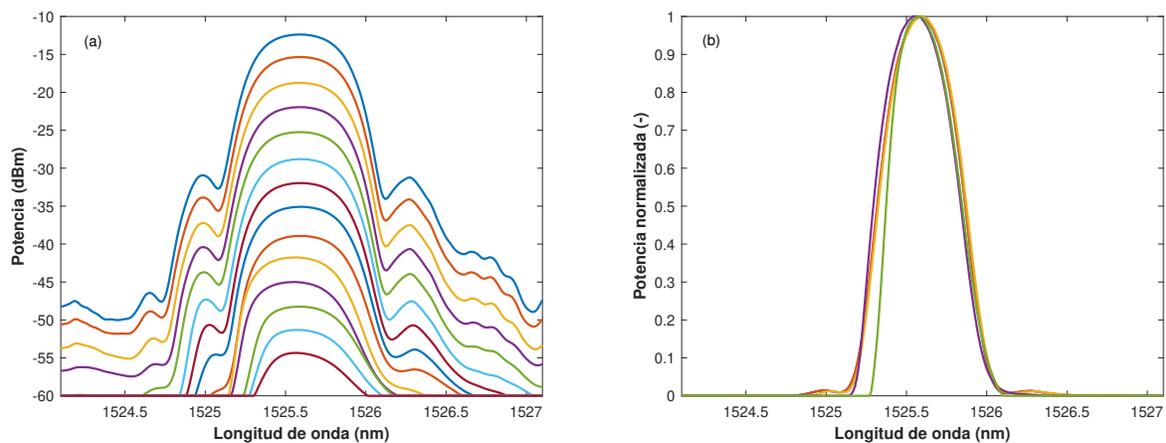


Figura 3.7: Reflectividades espectrales de FBG para diferentes niveles de atenuación, en (a) escala logarítmica y (b) escala lineal.

Además del estudio de desempeño del GPR como función de la atenuación (mostrado en la sección 3.2), también se estudia su robustez frente al muestreo espectral de los datos. El interrogador utilizado no permite cambiar el paso de muestreo espectral, como si lo hacen otros esquemas de interrogación que utilizan analizadores de espectros ópticos. Por esta razón, se utiliza un esquema de submuestreo (*downsampling*) para obtener de forma digital datos con diferentes muestreos espectrales. En la figura 3.8 se muestra el mismo espectro FBG (en escala lineal) al cual se le ha aplicado el submuestreo con diferentes factores de muestreo. En esta imagen el término *factor* se refiere al paso que existe entre cada muestra con respecto a la señal original. Por ejemplo, un factor igual a 4 quiere decir que se toma 1 de cada 4 muestras originales para generar la nueva señal, por lo que considerando un espectro original de 500 puntos, ahora se tienen solo 125 puntos. Cabe destacar que recién después de pasar por el submuestreo el espectro es normalizado entre 0 y 1, razón por la cual las amplitudes de los nuevos espectros pueden no corresponderse con las originales. Esto tiene como objetivo recrear lo que ocurriría en un sistema con un muestreo espectral arbitrario, cuyos datos solo pueden ser normalizados en base a los puntos. Es importante mencionar también que el algoritmo GPR es entrenado para una cantidad particular de puntos espectrales, por lo cual es necesario entrenar un modelo nuevo para cada muestreo analizado.

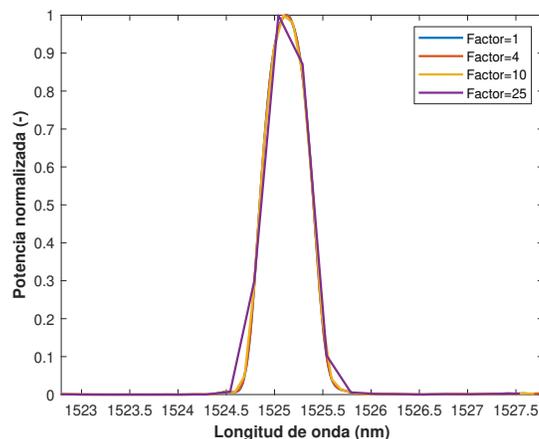


Figura 3.8: Resultado de submuestrear el espectro FBG medido.

Es importante también notar que el valor inicial tanto de longitud de onda como de potencia de todos los espectros submuestreados es el mismo, lo que podría ocasionar que la zona central del peak espectral siempre esté incluida en estos espectros. Esto presenta un problema puesto que en un sistema real de interrogación el peak no siempre coincidirá con los puntos espectrales que se están registrando, por lo que hacer el análisis de esta manera puede entregar un gran sesgo en los resultados. Para resolver este problema y realizar un correcto análisis estadístico de la robustez del algoritmo, se propone realizar el proceso de submuestreo a los espectros pero con diferentes muestras de inicio, es decir aplicando un offset a la posición espectral de la primera muestra. Así, la primera muestra del espectro submuestreado puede ser la muestra 1, 2, 3,  $\dots$ ,  $n$  donde  $n$  representa el factor del submuestreo. De esta manera, si se considera  $n = 4$ , para un espectro original de 500 puntos ahora se tendrían 4 nuevos espectros de 125 puntos, cada uno con una muestra

inicial diferente. La figura 3.9 muestra el resultado de este procedimiento, donde la línea puntuada representa el espectro original, y cada conjunto (triángulo, cuadrado, círculo o cruz) representa uno de los nuevos espectros generados a partir de un corrimiento (*shift*) diferente.

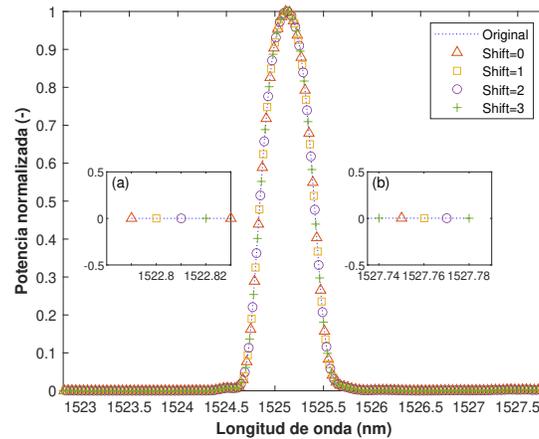


Figura 3.9: Resultado del *downsampling* con diferentes corrimientos espectrales.

Si bien este procedimiento permite hacer un análisis del desempeño que sea independiente de la posición inicial de los puntos espectrales, un nuevo problema se presenta para el algoritmo GPR, y es que como se puede ver en la figura 3.9 *insets* (a) y (b), cada uno de los nuevos espectros comienza y termina en una longitud de onda diferente. Como se mencionó anteriormente, el rango de longitudes de onda en el que se entrena y prueba este algoritmo debe ser exactamente el mismo para evitar errores, lo que evidentemente no se estaría cumpliendo si por ejemplo se entrena solo con el espectro con *shift* = 0. Para garantizar un buen análisis y que el rango de entrenamiento y prueba coincidan, se realiza un entrenamiento para desplazamiento (*shift*) del espectro. De esta manera, se asegura que cada modelo entrenado sea probado correctamente, de manera que se obtenga el error de forma estadística. Cabe mencionar que el entrenamiento a realizar para desplazamiento debe combinarse con el entrenamiento necesario para cada muestreo espectral.

### 3.1.3 Datos generados digitalmente

Dado que la forma espectral de la reflexión de un sensor FBG no cambia al sufrir variaciones de temperatura (o *strain*), se propone evaluar el desempeño de un modelo de entrenamiento basado en datos generados digitalmente. Este enfoque puede ofrecer la ventaja de no necesitar el registro de todos los espectros a medida que se aumenta la temperatura para tener un rango de entrenamiento aceptable. En este esquema se utiliza solo una medición espectral, obtenida por ejemplo a temperatura ambiente, y luego se desplaza digitalmente a lo largo del mismo rango de longitudes de onda de Bragg (o temperatura) que posee el conjunto de entrenamiento deseado. En este caso, el espectro se desplaza cada 10 pm (o 1 °C), lo que corresponde al paso de muestreo espectral del interrogador. Cabe notar que este paso produce un conjunto de datos cuyo tamaño es 100 veces menor que el original, lo que también es un aspecto interesante a destacar. El desplazamiento es generado con un corrimiento

circular, utilizando la función de Matlab *circshift*, la cual permite desplazar una señal en una cantidad entera de muestras. Futuros trabajos podrían explorar la posibilidad de realizar este corrimiento en valores no enteros. La longitud de onda de Bragg (o temperatura) de los espectros desplazados digitalmente también debe modificarse de forma proporcional a la magnitud del desplazamiento. Nótese que este desplazamiento, proporcional al paso de muestreo espectral, solo se aplica digitalmente a los datos de entrenamiento, mientras que el testeo de datos se hace con espectros desplazados arbitrariamente, como se mostrará en la sección 3.2.

La figura 3.10 muestra parte del resultado del desplazamiento digital, a lo largo de un rango de longitudes de onda de Bragg similar al del conjunto de entrenamiento original, en escala logarítmica y escala lineal. Se puede apreciar el efecto del corrimiento circular, en el cual las muestras finales del espectro original pueden aparecer al inicio de los espectros desplazados. Si bien esto altera la forma espectral, las amplitudes de los lóbulos laterales son bastante (más de 20 dB por debajo de la potencia del peak), por lo tanto tras la linealización y normalización no hay ningún efecto apreciable. Es interesante ver como este desplazamiento puede hacerse en cualquier sentido, siendo posible generar un rango de entrenamiento mucho mayor a lo que se podría medir de forma práctica, asumiendo que exista una cierta linealidad en la respuesta de los sensores FBG a los cambios de temperatura, en el rango deseado.

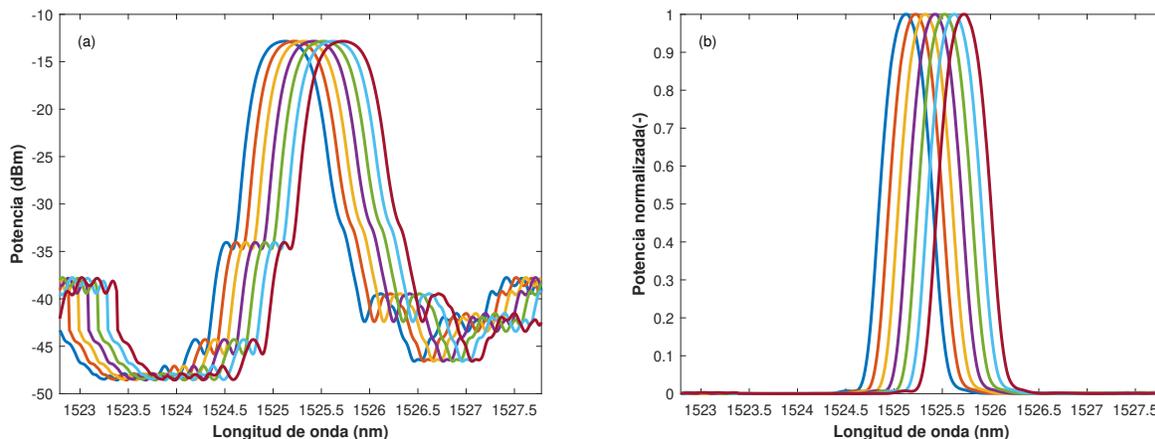


Figura 3.10: Desplazamiento digital de espectros FBG, en (a) escala logarítmica y (b) escala lineal.

## 3.2 Análisis y resultados

### 3.2.1 Metodología de análisis

Para cuantificar el desempeño del método GPR en cada escenario planteado se hará uso de las métricas *offset* RMS e incertidumbre. El *offset* RMS ( $\Delta\lambda_B^{RMS}$  o  $\Delta T^{RMS}$ ) evalúa la precisión del método a partir de la diferencia ( $\Delta\lambda_B$  o  $\Delta T$ ) entre los valores de longitud de onda de Bragg o temperatura calculados ( $\lambda_B^{pred}$  o  $T^{pred}$ ) y los valores de referencia ( $\lambda_B^{ref}$  o  $T^{ref}$ ). En este caso, los valores calculados son entregados por el interrogador de FBGs, mientras que los valores de referencia se obtienen a partir de una termocupla u otro sensor

FBG que no esté afectado por atenuación. El cálculo del *offset* RMS se lleva a cabo con la expresión 3.1, donde  $n$  corresponde al número de realizaciones de la muestra a analizar, es decir, los la cantidad de espectros medidos en la muestra.

$$\Delta\lambda_B^{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\lambda_B^{pred} - \lambda_B^{ref})^2} \quad (3.1)$$

Por otra parte, la incertidumbre da cuenta de la estabilidad o variación de las predicciones, siendo calculada como la desviación estándar de los valores de longitud de onda de Bragg o temperatura calculados por el método a una temperatura constante. Como se mencionó en la sección 3.1.2, los datos del conjunto de testeo experimentales son recolectados manteniendo la temperatura lo más estable posible, de forma que las correspondientes longitudes de onda de Bragg no varíen demasiado. Esto tiene como objetivo que la desviación estándar de los resultados sea afectada solo por la incertidumbre de los algoritmos. Sin embargo, como es prácticamente imposible que la temperatura no presente variaciones (figura 3.11) y debido a la alta sensibilidad de las FBGs, el cálculo realizado estará afectado por fluctuaciones térmicas. Por esta razón, se opta por calcular esta métrica como el valor mínimo de la desviación estándar evaluada sobre una ventana móvil de 10 realizaciones, de forma de estimar la desviación estándar que sea menos afectada por variaciones de temperatura.

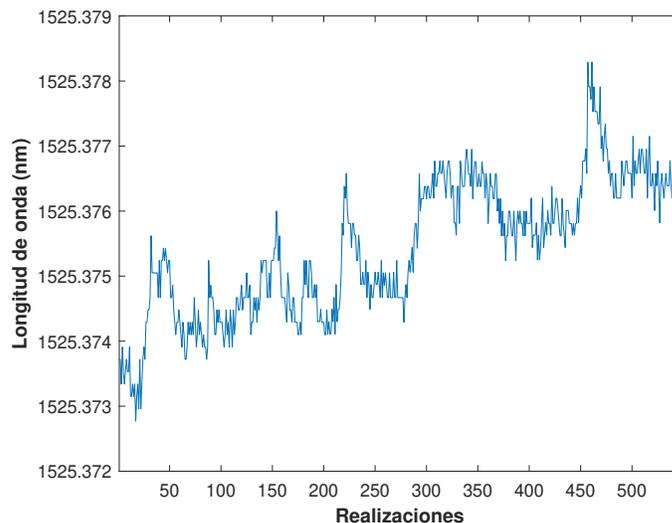


Figura 3.11: Variación de la longitud de onda de Bragg en una medición de testeo.

### 3.2.2 Resultados

En la figura 3.12 se muestran las predicciones hechas por el algoritmo GPR para un conjunto de datos con 0 dB de atenuación, cuya temperatura varía desde 25°C hasta 85°C, aproximadamente. Como se puede ver, los puntos de entrenamiento (puntos rojos) están espaciados equitativamente, según el paso de entrenamiento utilizado. La línea azul representa las predicciones hechas por el algoritmo para un conjunto de mediciones de testeo independiente al conjunto de entrenamiento. Se muestra además el intervalo de confianza que tienen estas

predicciones, dado por la misma función *predict* de Matlab. Este intervalo de confianza señala el espacio en el que con un 95 % de seguridad se encuentre el resultado esperado (franja amarilla), por lo que da cuenta de la varianza máxima de la predicción.

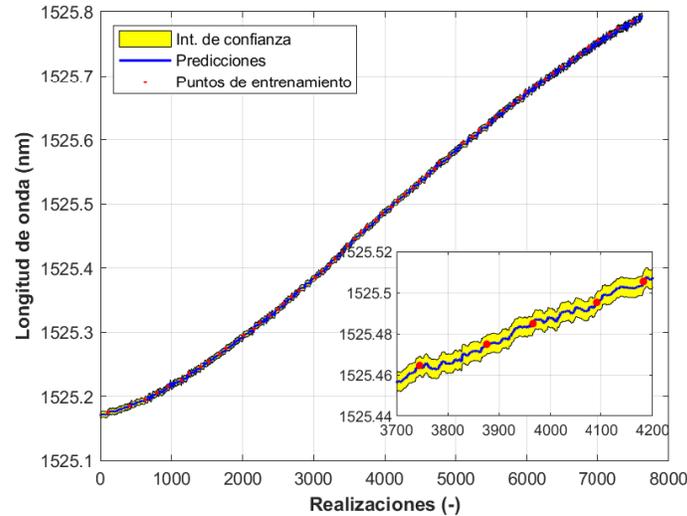


Figura 3.12: Predicción GPR con intervalos de confianza.

### Desempeño frente a la atenuación

A continuación se cuantifica y analiza la precisión e incertidumbre del algoritmo frente a diferentes valores de atenuación de los espectros medidos. La figura 3.13-(a) muestra cómo el *offset* RMS de la temperatura estimada por el método se mantiene relativamente constante en torno a  $0.1^{\circ}\text{C}$  para atenuaciones menores a 21 dB, aumentando de forma exponencial a medida que crece la atenuación desde este valor. Esto tiene total concordancia con lo esperado debido a que la forma espectral va perdiendo sus *side-lobes* al atenuar el espectro, lo que afecta directamente a las predicciones realizadas ya que el algoritmo funciona en base a la similitud de las formas espectrales. Cabe destacar también que los dos esquemas de entrenamiento (vale decir, el entrenamiento basado en datos puramente experimentales, y aquel basado en datos desplazados digitalmente) presentan un desempeño muy similar, por lo cual es posible concluir que el entrenamiento en base a corrimientos digitales es igual de aplicable que el caso experimental. Por otra parte, la figura 3.13-(b) muestra la incertidumbre (desviación estándar) del algoritmos frente a la atenuación. Es claro que esta métrica se mantiene constante cerca de  $0.01^{\circ}\text{C}$  en la mayoría de los casos, a excepción de cuando la atenuación es extremadamente alta. Esto da cuenta de la baja varianza de los resultados obtenidos, y por tanto de la alta repetibilidad de la estimación. Cabe mencionar que el valor medio de esta métrica se encuentra al menos un orden de magnitud por debajo de la precisión, lo que implica que el error de la temperatura estimada está esencialmente dominada por el *offset* introducido por el algoritmo y eventuales cambios en la forma espectral.

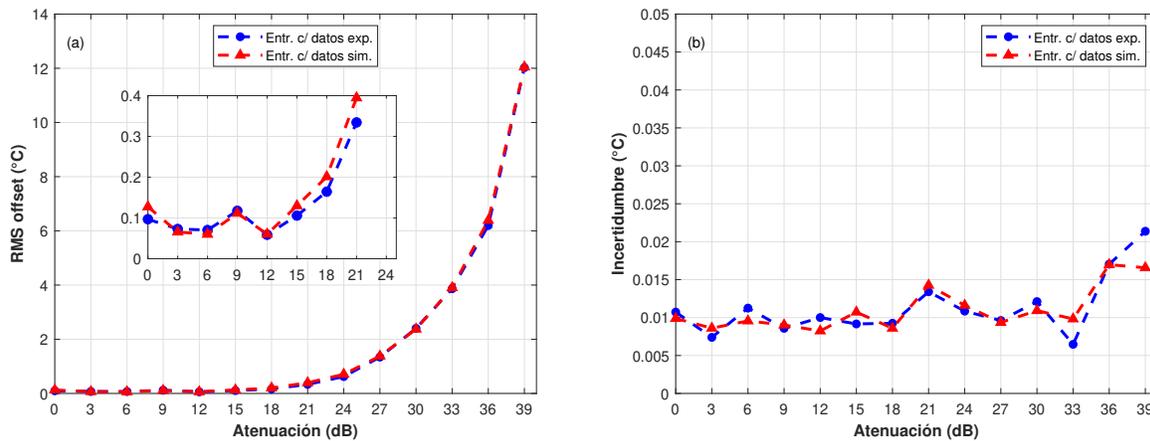


Figura 3.13: Resultados de (a) *offset* RMS e (b) incertidumbre vs atenuación con datos experimentales y digitales.

El siguiente estudio a realizar es en base a un nuevo entrenamiento, esta vez realizado con un conjunto de datos cuya atenuación es de 27 dB. El objetivo de esto es analizar como se comporta el método al ser entrenado con diferentes valores de atenuación, o en otras palabras, diferentes formas espectrales. Al igual que en el entrenamiento original, el paso de temperatura de este caso es de  $0.07^{\circ}\text{C}$ , y la temperatura varía desde los  $20^{\circ}\text{C}$  hasta los  $80^{\circ}\text{C}$ . La figura 3.14-(a) muestra el nivel de error RMS de tanto el entrenamiento experimental como el digital para diferentes valores de atenuación. Como es de esperar, el *offset* es mínimo al testear el algoritmo con una atenuación de 27 dB, lo que se debe a que en este caso las formas espectrales son las más similares al caso de entrenamiento. Para valores menores de atenuación, el error es mayor que en el caso mostrado anteriormente, debido claramente a las diferencias en las formas espectrales. Resulta interesante además que, para valores de atenuación mayores a los 27 dB, el nivel de error también aumenta de forma exponencial, pero en una menor medida que en el entrenamiento con 0 dB. Esto da cuenta de que sería posible entrenar con diferentes niveles de atenuación de acuerdo al valor con el que se espere testear el algoritmo. Este crecimiento de error tiene origen en la misma razón expuesta anteriormente, los cambios en la forma espectral. Como parte de un posible trabajo futuro se podría investigar el valor óptimo de atenuación para obtener el menor error posible, o se podría estudiar un esquema que utilice múltiples entrenamientos, de forma tal que el error sea minimizado localmente.

Resulta interesante observar que en el caso del entrenamiento con 27 dB de atenuación, el entrenamiento basado en datos desplazados digitalmente no tiene un desempeño tan bueno como el basado en datos experimentales. Esto puede deberse a la forma espectral modificada. De todas formas, los comportamientos son similares. En la figura 3.14-(b) se muestra la incertidumbre calculada para este caso, la que muestra cómo la varianza de los resultados se mantiene constante en casi todo el rango de testeo, alrededor de los  $0.01^{\circ}\text{C}$ .

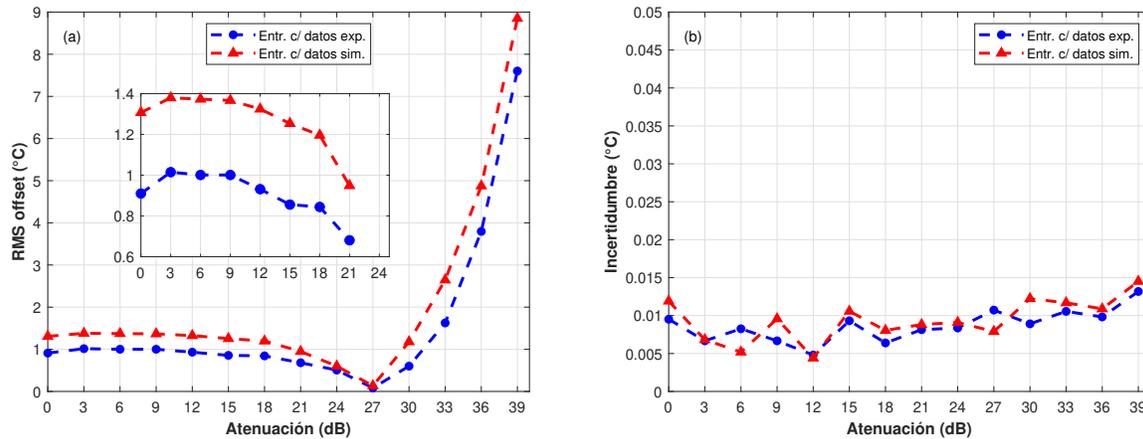


Figura 3.14: Resultados de (a) *offset* RMS e (b) incertidumbre vs atenuación con datos experimentales y digitales, entrenados con 27 dB de atenuación.

### Desempeño frente a temperatura

La figura 3.15-(a) muestra la comparación entre las temperaturas estimadas por el algoritmo y las de referencia para conjuntos de datos de entrenamiento y testeo sin atenuación, además de una línea con pendiente unitaria que representa el caso ideal en que no hay diferencia entre estos valores. Como se puede notar, tanto el entrenamiento con datos experimentales como el con datos digitales presentan un comportamiento similarmente bueno a lo largo de todo el rango de temperaturas que fue testeado. Esto da cuenta una vez más de la buena respuesta que tiene el algoritmo en la detección de temperaturas a partir de espectros FBG. Cabe destacar que el rango de temperaturas utilizado en este testeo (25-80°C) es ligeramente menor al rango de entrenamiento (20-90°C), ya que se esperaría que en las temperaturas extremas el error incremente sustancialmente si es que ambos rangos fueran similares o si el entrenamiento es en un rango menor que el de testeo. Esto se puede observar mejor en la figura 3.16, donde se muestran los resultados del mismo experimento pero utilizando un rango de entrenamiento entre 40°C y 65°C, es decir, un rango menor que el de testeo. Resultaría interesante investigar, como parte de un trabajo futuro, los límites de temperatura de entrenamiento que pueden ser utilizados de forma tal que aún se obtengan buenos resultados.

Por otro lado, en la figura 3.15-(b) se puede ver la comparación entre las temperaturas estimadas y de referencia para datos de testeo con una atenuación de 27 dB. En este caso se puede apreciar un claro *offset* entre las curvas resultantes de ambos esquemas de entrenamiento (experimental y digital) y la línea con pendiente unitaria, lo que da cuenta del nivel de error constante existente en estas estimaciones, en concordancia con lo visto en la figura 3.13-(a), donde se aprecia un considerable *offset* RMS para este valor de atenuación. No obstante, se puede destacar que ambos esquemas de entrenamiento presentan un desempeño bastante similar, lo que permite concluir nuevamente respecto a la utilidad y buen funcionamiento del método propuesto.

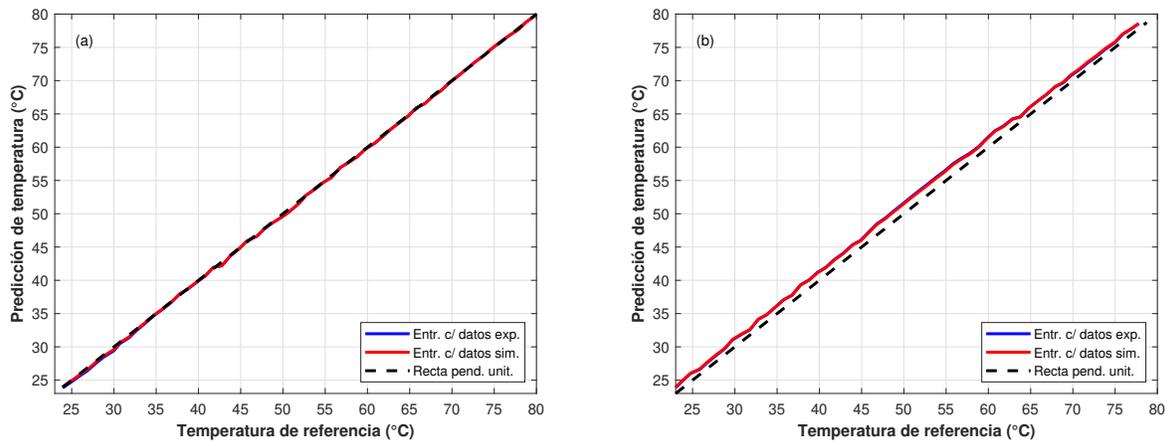


Figura 3.15: Predicción de temperatura vs temperatura de referencia con datos experimentales y digitales, para una atenuación de (a) 0 dB y (b) 27 dB.

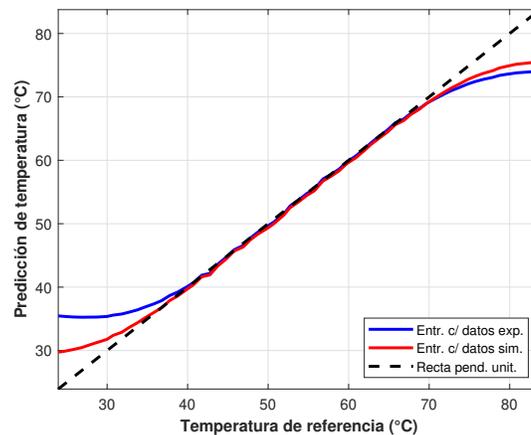


Figura 3.16: Predicción de temperatura vs temperatura de referencia, con datos experimentales y virtuales para un entrenamiento en menor rango de temperatura.

Un aspecto a tomar en cuenta es que en los dos casos mostrados en la figura 3.15 el error parece ser constante a lo largo de todo el rango de temperatura, con algunas ligeras excepciones. Esto se puede analizar con más detalle en la figura 3.17, donde se exhibe la diferencia absoluta entre los valores de temperatura estimados y los de referencia, para diferentes atenuaciones del conjunto de datos de testeo. Cabe destacar que para mayor claridad de la figura solo se muestran los resultados obtenidos cada  $1^{\circ}\text{C}$ . En ambas imágenes es posible apreciar cómo el error absoluto se mantiene mayormente constante a lo largo de todo el rango de temperatura, con ligeras excepciones propias de la cantidad de realizaciones utilizadas en la predicción. Se puede notar además que en el caso de los datos con 27 dB de atenuación el error absoluto tiene una media mayor al caso sin atenuación. Esto está de acuerdo a lo esperado debido a las diferencias en las formas espectrales observadas entre el caso sin atenuación y el caso con una atenuación de 27 dB. Por último, en la figura 3.18 se muestra

el comportamiento del *offset* absoluto al tener un entrenamiento con un acotado rango de temperaturas (40 a 65 °C). Es que fuera de este rango el error aumenta significativamente, pero manteniéndose en los mismos niveles vistos en la figura 3.15 cuando se está dentro de estas temperaturas.

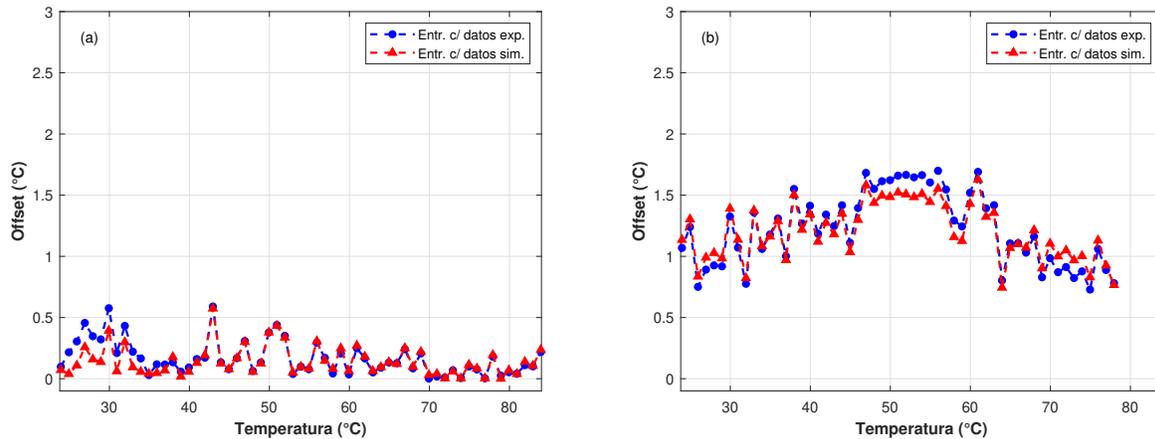


Figura 3.17: Resultados de offset vs temperatura con datos experimentales y digitales para atenuaciones de (a) 0 dB y (b) 27 dB.

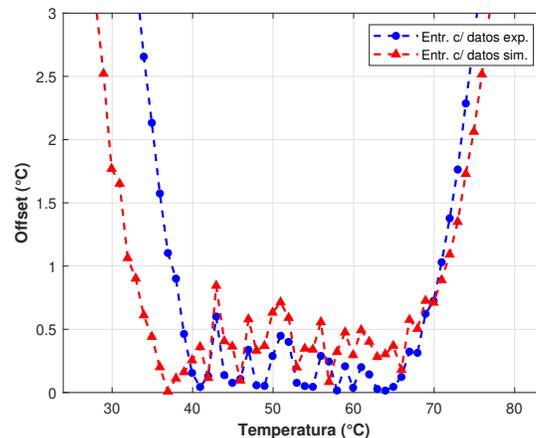


Figura 3.18: Resultados de offset vs temperatura con datos experimentales y digitales para un entrenamiento en menor rango de temperatura

### Desempeño frente a paso de temperatura de entrenamiento

A continuación se estudia el desempeño del GPR en función del paso de temperatura utilizado para entrenar el algoritmo. Como se menciona en la sección 3.1.2, el GPR presenta un menor nivel de error al ser entrenado con un paso de temperatura superior a 0.01 °C, lo que se puede comprobar en la figura 3.19-(a), donde se muestra el comportamiento del *offset* RMS frente a diferentes configuraciones de paso de entrenamiento. En esta figura

se puede apreciar que el valor de error para un paso de  $0.01^{\circ}\text{C}$  es algo mayor que en, por ejemplo  $0.07^{\circ}\text{C}$ , lo que da cuenta del sobreajuste del modelo frente a los datos con tan poca diferencia de temperatura. Es por esta razón que en este trabajo todos los modelos de GPR son entrenados con un paso de  $0.07^{\circ}\text{C}$ . No obstante, este sobreajuste bien puede deberse a la forma en que los datos son recolectados, vale decir, los valores de temperatura registrados no son estrictamente crecientes, y su crecimiento tampoco es demasiado rápido, por lo cual pueden llegar a existir repetidas mediciones espectrales para una misma temperatura, o que la temperatura cambie durante una misma medición. En cualquier caso, es claro que utilizar un conjunto de datos con un mayor paso de temperatura solo resulta beneficioso para el desempeño del algoritmo.

La figura 3.19-(a) también muestra el *offset* RMS para el esquema de entrenamiento basado en datos desplazados virtualmente. Este análisis solo se realiza desde un paso de temperatura igual a  $1^{\circ}\text{C}$ , ya que este es el mínimo valor con el que se pueden desplazar los espectros a partir de un número entero de realizaciones. Para ambos esquemas de entrenamiento el resultado es similar, obteniéndose bajos valores de error para pasos menores a  $5^{\circ}\text{C}$  y elevándose considerablemente después de este valor, lo que se debe a que con pasos de temperatura tan altos se obtiene un conjunto de datos de entrenamiento demasiado pequeño y poco cohesionado, por lo que el algoritmo simplemente deja de funcionar y entrega resultados sin sentido. Por otra parte, la figura 3.19-(b) muestra el comportamiento de la incertidumbre del algoritmo frente a diferentes pasos de entrenamiento. Al igual que en la precisión, la incertidumbre muestra un comportamiento mayormente constante hasta llegar a un paso de  $5^{\circ}\text{C}$ , donde empieza a mostrar valores muy grandes y variados, debido al mal funcionamiento del algoritmo en conjuntos de datos muy pequeños.

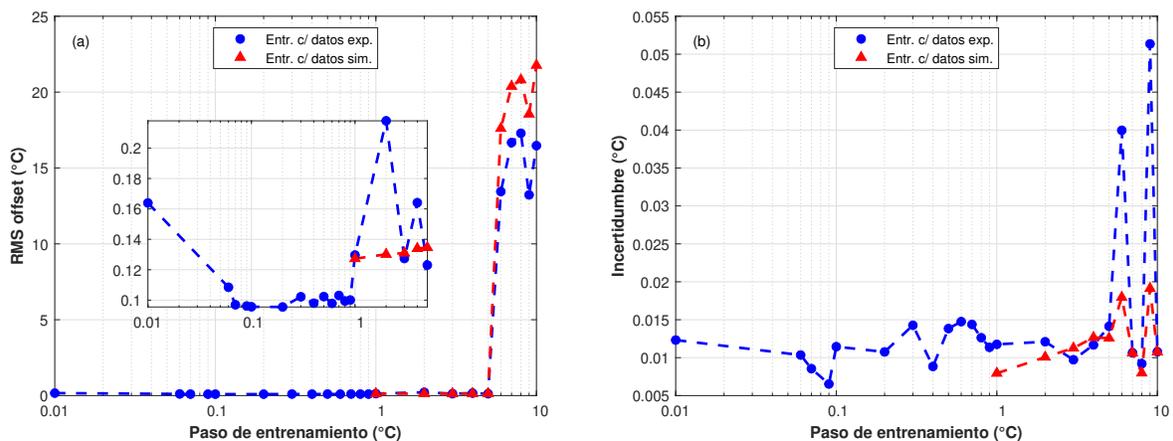


Figura 3.19: Resultados de (a) *offset* RMS y (b) incertidumbre vs paso de temperatura de entrenamiento con datos experimentales y digitales.

### Desempeño frente a muestreo espectral

Finalmente, se analiza el funcionamiento del algoritmo GPR frente a variaciones del muestreo espectral. Como se detalla en la sección 3.1.2, para variar el muestreo espectral de las

mediciones, éstas deben ser submuestreadas. En este caso se utilizan pasos de submuestreo de 2, 4, 5, 10, 20, 25, 50 y 100 muestras espectrales. Considerando que las mediciones originales de los espectros poseen 500 puntos espectrales, los espectros submuestreados tendrán entre 5 y 250 muestras. Cabe resaltar que este estudio no se hace exactamente respecto a diferentes muestreos espectrales, sino que frente a la cantidad de puntos que se registran en la zona del peak espectral, debido a que esta es una métrica más absoluta para cuantificar el desempeño del algoritmo. El número de puntos en la zona del peak espectral es calculado considerando aquellas muestras espectrales que tengan una amplitud mayor o igual al 10% de la potencia máxima del espectro. Considerando que los espectros FBG tienen un ancho espectral de aproximadamente 1.1 nm, y que la tasa de muestreo espectral es de 10 pm, la zona del peak tendrá aproximadamente 110 puntos para la medición original (no submuestreada).

La figura 3.20-(a) muestra el *offset* RMS frente a la cantidad de puntos en el peak, variando desde 1 a 110 puntos (valores obtenidos a partir de los diferentes pasos de submuestreo detallados anteriormente). Es claro como el algoritmo presenta un desempeño relativamente constante al tener 2 o más puntos en la zona del peak, mientras que cuando solo hay 1 punto el nivel de error aumenta considerablemente. Este comportamiento está dentro de lo aceptable y lo esperado, ya que como ha sido demostrado en [27, 28], el GPR posee una enorme robustez al muestreo espectral. Se puede volver a destacar como ambos esquemas de entrenamiento, tanto digital como experimental, presentan desempeños muy similares. La incertidumbre del algoritmo es relativamente constante frente a la cantidad de puntos en la zona del peak espectral, como se puede ver en la figura 3.20-(b).

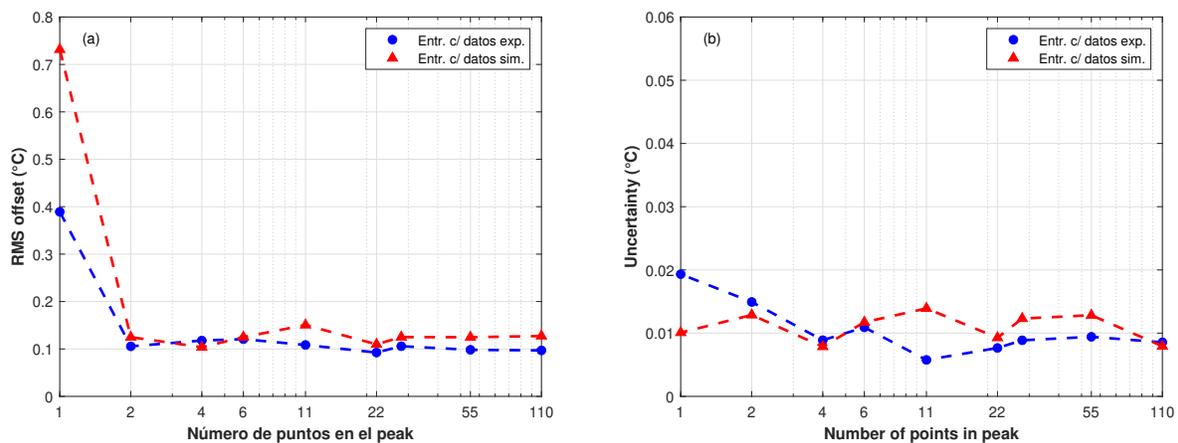


Figura 3.20: Resultados de (a) *offset* RMS y (b) incertidumbre vs cantidad de puntos en peak con datos experimentales y virtuales

### 3.2.3 Análisis

Los resultados mostrados en la sección anterior permiten conocer los límites funcionales del GPR, además de sus limitaciones prácticas. En primer lugar, el algoritmo es fuertemente sensible a las variaciones de las formas espectrales utilizadas tanto para entrenar como

testear, por lo que es imperativo tener precaución que las mediciones no sufran de excesivos niveles de atenuación o ruido si se quieren obtener buenos resultados al implementar el algoritmo. Esto puede tener fuertes implicancias en la interrogación de sensores FBG instalados a largas distancias del dispositivo de medición, situación en la cual la atenuación es un importante factor limitante. Esta implementación en particular presenta niveles de error aceptables para atenuaciones menores a 21 dB, lo que permitiría la instalación de sensores alejados hasta en 50 km del sistema de interrogación. Por otro lado, se ha verificado la gran robustez del algoritmo frente al muestreo espectral, la cual convierte al método en una viable alternativa cuando se posee un bajo número de muestras espectrales en la zona del peak de la FBG. El desempeño del GPR se ve afectado de forma considerable cuando se tiene solo 1 punto en la zona del peak, lo que puede considerarse como una situación bastante inusual dada las tasas de muestreo espectral que manejan los equipos actuales.

También se puede destacar la importancia de la correcta elección del rango de temperaturas (o longitudes de onda de Bragg) con las cuales se entrena el algoritmo, debido a que si el sistema es utilizado para un rango que no coincide con el de entrenamiento, se observarán altos niveles de error en las predicciones realizadas. De igual manera, contar con un conjunto de datos de entrenamiento de un tamaño razonable es sumamente importante para evitar excesivos tiempos de cómputo y el sobreajuste del modelo, lo que a su vez guarda relación con el paso de temperatura que tengan las mediciones. Se ha demostrado cómo en esta implementación el GPR sufre de *overfitting* al ser entrenado con un paso de  $0.01^{\circ}\text{C}$ . Resulta interesante observar qué cualquier paso de temperatura para el entrenamiento que sea mayor a este valor y menor a  $5^{\circ}\text{C}$  entrega resultados bastante similares, sobre todo tomando en cuenta que mientras más grande sea el paso, menor es la cantidad de datos con los que se entrena. Entonces, un modelo GPR podría ser entrenado sin problemas con un paso de temperatura de, por ejemplo  $1^{\circ}\text{C}$ , lo que requeriría de un conjunto de datos bastante más acotado que el originalmente utilizado en este análisis. Esto presenta una gran ventaja para el algoritmo debido al bajo tiempo de cómputo de entrenamiento que requeriría su implementación.

Se ha demostrado la considerable estabilidad que tiene el algoritmo GPR en sus predicciones, lo que se puede confirmar a partir de los cálculos de incertidumbre realizados en este estudio. La mayoría de éstos muestra cómo la desviación estándar de las predicciones está por lo general un orden de magnitud por debajo de sus valores de error. Finalmente, se verifica la utilidad y robustez del esquema de entrenamiento basado en el desplazamiento digital de los espectros FBG medidos. Este esquema tiene la potencial ventaja de facilitar el entrenamiento del algoritmo y también agilizar la toma de datos necesarios. Cabe destacar que este enfoque requiere una correcta caracterización de la forma espectral de la FBG y de la forma en que esta se desplaza a medida que cambia la temperatura.

## Capítulo 4

# Implementación y comparación de desempeño de algoritmos clásicos y GPR

En este capítulo se detalla la implementación de los algoritmos clásicos seleccionados, es decir, el centroide y el ajuste polinomial, además de comparar su desempeño con el del algoritmo GPR en diferentes configuraciones de ruido, atenuación y muestreo espectral. Este análisis se inicia con la aplicación de los algoritmos utilizando datos simulados computacionalmente en base a un modelo matemático de la forma espectral de una FBG, para luego continuar con la comparación de desempeño usando los datos experimentales descritos en el capítulo anterior.

### 4.1 Detalles sobre implementación de algoritmos y simulación de datos

La implementación de todos los algoritmos seleccionados se lleva a cabo en Matlab, debido a la existencia de librerías y funciones que facilitan la programación de procesos como la regresión cuadrática. Es importante destacar que a diferencia del capítulo anterior, donde el algoritmo GPR es utilizado para detectar valores de temperatura, este análisis se hace en base a la detección de la longitud de onda de Bragg de los espectros. Esto se debe a que los algoritmos clásicos implementados están diseñados para detectar la ubicación de un peak espectral, el cual está estrechamente relacionado con la longitud de onda de Bragg.

#### Centroide

El primer algoritmo a implementar es el centroide, descrito matemáticamente en la sección 2.2.1. Inicialmente este método se aplica a la totalidad del espectro a analizar, incluyendo tanto lóbulos laterales como longitudes de onda donde no hay reflectividad. Sin embargo, al realizar algunas pruebas se llega a la conclusión de que el algoritmo funciona mejor al ser aplicado solo a la parte central del espectro, por lo que es necesario realizar un procedimiento de thresholding similar al mencionado para el método X-dB en la sección 2.2.1. A continuación se muestra el script de Matlab utilizado para implementar este algoritmo (código 4.1), donde se puede notar el uso de la función *threshold*, la cual se detalla posteriormente (código 4.2). Cabe destacar que este programa calcula y retorna la longitud de onda de Bragg directamente a partir del espectro y las longitudes de onda correspondientes.

```

1 function lambda_centroid = centroid(R,lambda)
2     % R: Vector de espectro a analizar
3     % lambda: Vector de longitudes de ondas correspondientes
4
5     % Threshold
6     [R_centr,lambda_centr] = threshold(R,lambda,0.5);
7
8     sum_1 = 0;
9     sum_2 = 0;
10    for i = 1:size(lambda_centr,2)
11        sum_1 = sum_1 + lambda_centr(:,i)*R_centr(:,i);
12        sum_2 = sum_2 + R_centr(:,i);
13    end
14    lambda_centroid = sum_1/sum_2;
15 end

```

Codigo 4.1: Implementacion del centroide.

```

1 function [R_out,lambda_out] = threshold(R_in,lambda_in,thresh)
2     % R_in: Vector de espectro a recortar
3     % lambda_in: Vector de longitudes de onda
4     % thresh: Valor de threshold (0-1).
5
6     R_max = max(R_in);
7     init = 0;
8     final = 0;
9
10    for i = 1:size(R_in,2)
11        if (R_in(i) >= R_max*thresh) && init == 0
12            init = i;
13            if init == 1
14                init = 2;
15            end
16        elseif (R_in(i) <= R_max*thresh) && init ~= 0 && final == 0
17            final = i;
18        elseif (R_in(i) >= R_max*thresh) && final ~= 0
19            final = i;
20        end
21    end
22
23    R_out = R_in(:,init-1:final);
24    lambda_out = lambda_in(:,init-1:final);
25 end

```

Codigo 4.2: Implementacion de thresholding.

A modo de ejemplo, en la figura 4.1 se detallan algunos aspectos de esta implementación, donde las líneas puntuadas denotan la sección del espectro a analizar, obtenida a partir de la rutina de *thresholding* con un valor de threshold de 0.5, y las líneas verticales representan la longitud de onda de Bragg de referencia y la calculada por el algoritmo. Se puede notar una diferencia entre el valor calculado y el de referencia, correspondiente al *offset* del resultado, el cual se puede deber a que la forma espectral no está perfectamente centrada con respecto a la longitud de onda de referencia.

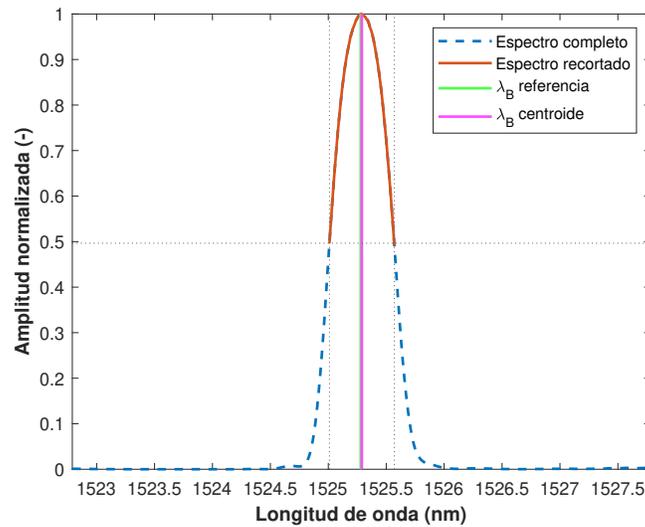


Figura 4.1: Ejemplo de funcionamiento y resultado del centroide.

### Ajuste polinomial

El siguiente algoritmo a implementar es el ajuste polinomial, descrito en la sección 2.2.2. Como se menciona en dicha sección, este algoritmo realiza un ajuste de curva del espectro medido con respecto a alguna función polinomial, en este caso de segundo orden (cuadrática). En el código 4.3 se muestra la función de Matlab utilizada para implementar este algoritmo, en la cual al igual que en el centroide se utiliza la rutina de *thresholding* para recortar el espectro y aplicar el ajuste solo a la parte central de este, lo que mejora su desempeño. En este caso el ajuste polinomial se realiza con la función de Matlab *polyfit*, lo que facilita su implementación. Esta función entrega como resultado el valor de los coeficientes de la ecuación cuadrática, a partir de los cuales se calcula el valor máximo del polinomio igualando a cero la derivada de éste, como se presenta en la ecuación 2.9.

```

1 function lambda_fit_pol = pol_fit(R,lambda)
2     % R: Vector de espectro a analizar
3     % lambda: Vector de longitudes de ondas correspondientes
4
5     % Threshold
6     [R_fit,lambda_fit] = threshold(R,lambda,0.5);
7
8     % Polinomial fit
9     p1 = polyfit(lambda_fit,R_fit,2);
10    lambda_fit_pol = -p1(2)/(2*p1(1));

```

Código 4.3: Implementación ajuste polinomial.

En la figura 4.2 se muestra un ejemplo del funcionamiento de este algoritmo, donde las líneas puntuadas denotan la sección del espectro que será ajustada al polinomio mostrado. Se puede observar que este polinomio tiene una forma muy similar a la parte central del espectro. A pesar de esto, existe un *offset* entre la longitud de onda de Bragg de referencia y la encontrada por el algoritmo, el cual eventualmente podría ser mayor cuando exista mayor atenuación, ruido o menor número de muestras espectrales. Este error puede deberse a que la forma espectral no se adecúa perfectamente a una curva cuadrática.

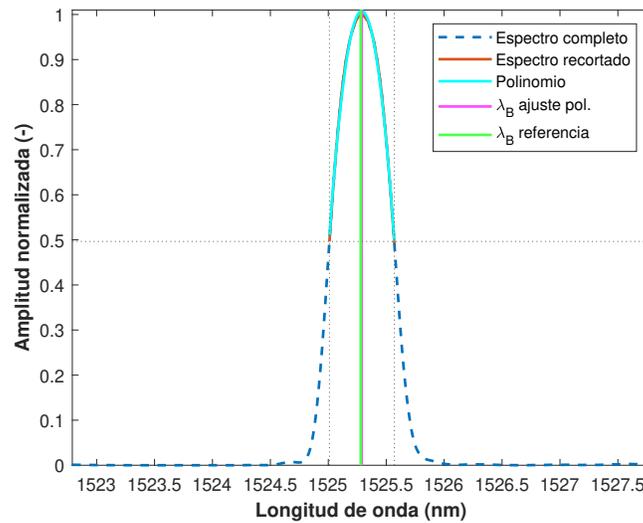


Figura 4.2: Ejemplo de funcionamiento y resultado del ajuste polinomial.

#### 4.1.1 Datos simulados

Para probar el desempeño de los algoritmos seleccionados primero se utilizan espectros simulados a partir de la ecuación 2.3, la cual expresa la relación entre la reflectividad (o espectro) de la FBG y la longitud de onda, junto con varios otros parámetros como el largo de la rejilla, la magnitud del cambio del índice de refracción, el índice de refracción efectivo del núcleo de la fibra y la longitud de onda de Bragg. En este caso se simulan reflectividades con un rango de longitudes de onda entre 1525 y 1530 nm, con un muestreo espectral de 10 pm. En el código 4.4 se muestran los comandos y parámetros utilizados para generar un espectro FBG con una longitud de onda de Bragg de 1527.5 nm. Cabe destacar que el espectro es normalizado entre 0 y 1 con la función de Matlab *rescale*.

```

1  % Parametros:
2  n_eff = 1.5;           % Índice de refraccion efectivo
3  delta_n = 10^(-6);    % Magnitud del cambio de indice de refraccion
4  L = 0.01;            % Largo de la rejilla (m)
5  k = 1.5/L;          % 'Intensidad' de la rejilla
6  bragg = 1527.5*10^(-9); % Longitud de onda de Bragg
7  t_m = 10*10^(-12);   % Muestreo espectral
8  lambda = 1525*10^(-9) : t_m : 1530*10^(-9) - t_m; % Longitudes de onda
9
10 % Espectro FBG
11 sigma = pi*delta_n./lambda + 2*pi*n_eff*( 1./lambda - 1/ bragg );
12 R = sinh(L*sqrt(k^2-sigma.^2)).^2 ./ (cosh(L*sqrt(k^2-sigma.^2)).^2 - sigma.^2/
    k^2 );
13 R = rescale(R);

```

Código 4.4: Simulación del espectro de una FBG.

Para realizar un correcto estudio estadístico del desempeño de los algoritmos es necesario contar con un conjunto de datos lo suficientemente grande de forma que las métricas utilizadas para cuantificar el rendimiento sean válidas. Por esta razón, se procede a generar un conjunto de datos con mil realizaciones, cada una de las cuales posee una longitud de onda

de Bragg diferente designada aleatoriamente usando la función de Matlab *rand*, la cual distribuye uniformemente los valores. Las longitudes de onda de Bragg son centradas en 1527.5 nm y poseen una variación máxima de  $\pm 50\text{pm}$ , con lo que se tiene un rango entre 1527.45 nm y 1527.55 nm. Como se menciona en el capítulo anterior, para que el entrenamiento del GPR sea realizado correctamente se necesita que el rango de longitudes de onda de Bragg de entrenamiento sea igual o mayor que el rango de testeo, por lo que para generar el conjunto de entrenamiento también se varía la longitud de onda de Bragg. En este caso, las longitudes de onda de Bragg de entrenamiento varían de forma creciente (no aleatoria) cada 1 pm entre los 1527.4 y 1527.6 nm, con lo que se tiene un dataset de 200 realizaciones, cada una con una longitud de onda de Bragg diferente. En la figura 4.3 se muestra una selección de los espectros simulados de entrenamiento, cuyas longitudes de onda de Bragg varían crecientemente. Cabe mencionar que para el cálculo de la incertidumbre de los algoritmos se genera un conjunto de espectros cuyas longitudes de onda de Bragg son iguales, de forma tal que idealmente no exista variación en los resultados y así el cálculo de la incertidumbre esté afectado solo por la resolución propia de cada algoritmo.

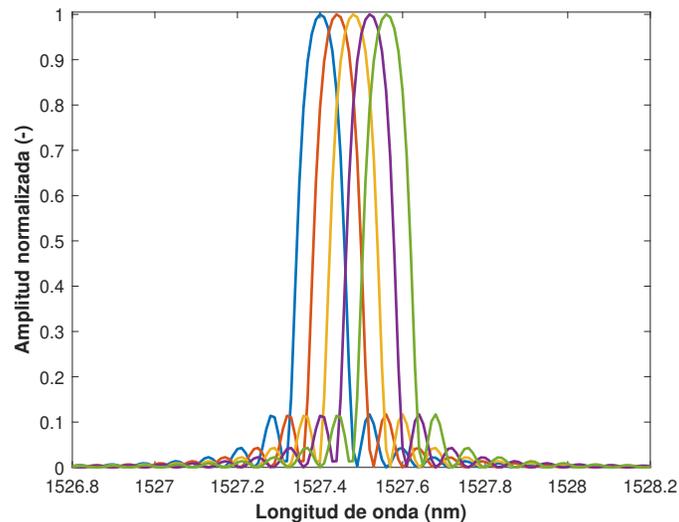


Figura 4.3: Ejemplo de algunos de los espectros FBG utilizados para el entrenamiento del algoritmo.

Finalmente, para llevar a cabo el análisis del funcionamiento de los algoritmos seleccionados se estudia su desempeño frente a diferentes condiciones de ruido y muestreo espectral, para lo cual es necesario generar conjuntos de datos con diferentes valores de SNR (Signal-to-Noise Ratio) y tasas de muestreo ( $T_m$ ). En cuanto a la variación del nivel de ruido, se utiliza la función vista en el código 4.5, la cual agrega ruido al espectro con un valor de desviación estándar calculado a partir de la SNR deseada. De esta manera, para cada valor de SNR se tendrá un conjunto de datos de 1000 realizaciones de ruido diferentes. Cabe destacar que los espectros ingresados a esta función ya deben estar normalizados entre 0 y 1. En el caso del entrenamiento del algoritmo GPR se utiliza un conjunto de datos con una SNR igual a 60 dB. En la figura 4.4-(a) se muestran simulaciones espectrales para diferentes niveles de ruido. Por otro lado, para variar el muestreo espectral de la simulación basta con cambiar el valor  $t_m$  visto en el código 4.4, con lo cual se generan espectros con menos puntos espectrales, como los vistos en la figura 4.4-(b). Es importante mencionar que en el caso del GPR para

cada muestreo espectral se debe generar y entrenar un modelo diferente, ya que estos son entrenados con una cantidad fija de puntos espectrales.

```

1 function R_out = add_noise(R_in,snr_db)
2     % R_in: Espectro normalizado al cual agregar ruido
3     % snr_db: SNR deseada, en dB
4     snr_lin = 10^(snr_db/10);
5     noise_std = 1/snr_lin;
6     noise = noise_std * randn(size(R_in));
7     R_out = R_in + noise;
8 end

```

Código 4.5: Función para agregar ruido al espectro de una FBG.

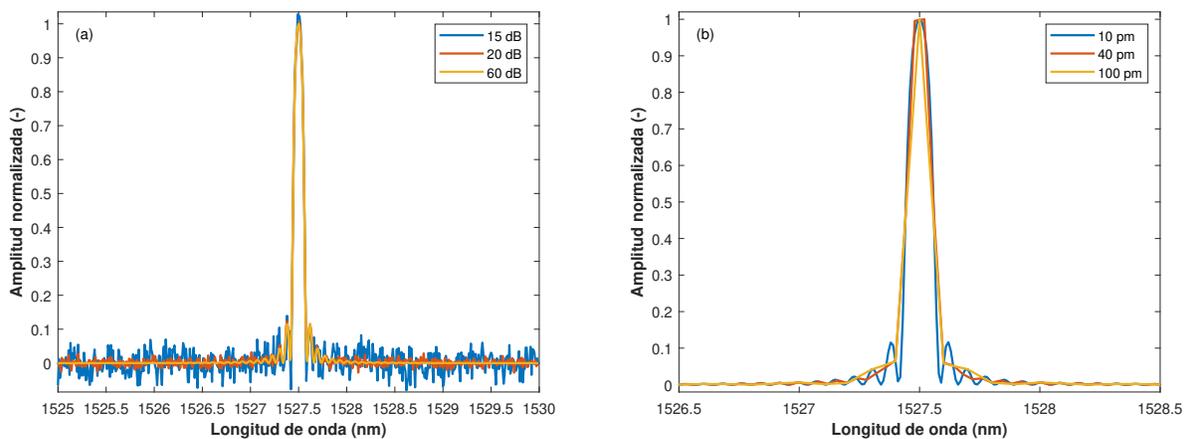


Figura 4.4: Simulaciones de espectros FBG con (a) diferentes valores de SNR = 15, 20, 60 dB y (b) diferentes tasas de muestreo ( $T_m$ ) = 10, 40, 100 pm.

## 4.2 Análisis de error de métodos de detección de ubicación del peak espectral

### 4.2.1 Resultados con datos simulados

El primer análisis a realizar a partir de datos simulados se relaciona al desempeño de los algoritmos frente a diferentes niveles de ruido de los espectros, variando la SNR entre 10 y 60 dB, con un muestreo espectral de 10 pm. Es importante destacar que para el caso del GPR, el entrenamiento se lleva a cabo con un conjunto de datos cuya SNR es igual a 60 dB. La figura 4.5-(a) muestra el *offset* RMS de los 3 algoritmos analizados en función de los niveles de ruido. Los resultados muestran que el método GPR entrega valores de error mucho más bajos que los demás algoritmos en configuraciones poco ruidosas, mientras que para una SNR < 20 dB su desempeño es bastante pobre en comparación al ajuste polinomial y el centroide. Esto se puede explicar en base a que el GPR aprende una forma espectral para generar predicciones, y al haber mucho ruido dichas formas presentan importantes alteraciones con respecto al entrenamiento.

Por otro lado, la figura 4.5-(b) muestra el comportamiento de la incertidumbre propia de los algoritmos frente al aumento del ruido. Se puede apreciar que esta métrica es prácticamente constante para niveles de SNR mayores a 30 dB, mientras que en configuraciones altamente ruidosas aumenta considerablemente, sobretodo para el caso del GPR, debido a las mismas razones por las cuales el *offset* aumenta. Se puede concluir que el algoritmo GPR no es muy robusto en situaciones donde el nivel de ruido entorpece las mediciones, mientras que algoritmos como el centroide o el ajuste polinomial presentan un desempeño ligeramente mejor, pero sin dejar de verse afectados por dicho ruido. Cabe destacar que este análisis solo se realizó en base a datos simulados debido a que en el esquema real implementado y descrito en la figura 3.1 no es posible agregar ruido a las mediciones de forma artificial.

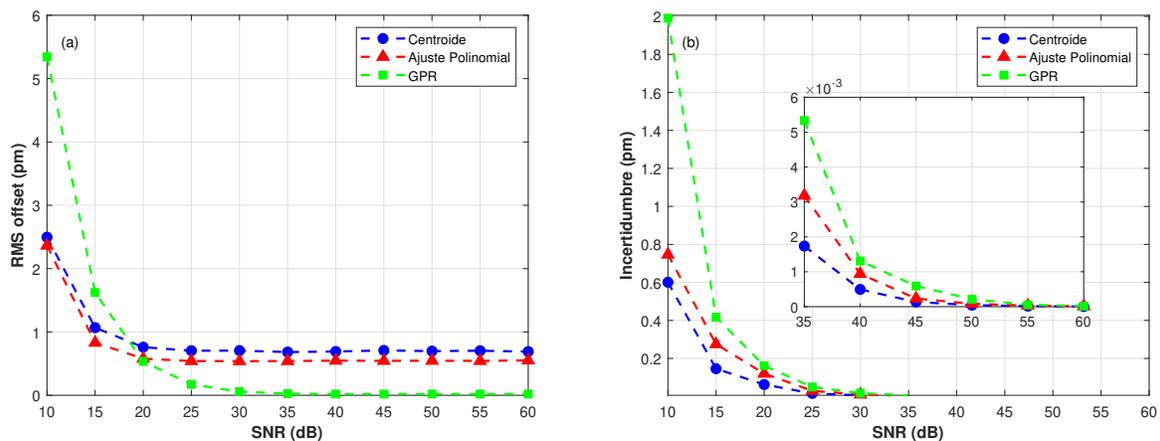


Figura 4.5: Resultados de (a) *offset* RMS y (b) incertidumbre vs SNR con datos simulados, utilizando un muestreo de 10 pm.

En la figura 4.6-(a) se muestra el *offset* RMS de los 3 algoritmos frente a diferentes muestreos espectrales (de 10 pm, 20 pm, 50 pm y 200 pm), sin ruido agregado. Cabe destacar que este análisis se lleva a cabo en relación a la cantidad de puntos en la zona del peak en vez de la tasa de muestreo espectral propiamente tal, debido a que es una métrica más absoluta. En este caso, la cantidad de puntos espectrales está calculada como el número de puntos cuya amplitud es mayor a 0.15 (para evitar los lóbulos laterales). Considerando que los espectros simulados tienen un ancho espectral cercano a 0.15 nm, se obtiene un total de 14, 8, 3 y 1 puntos en la zona del peak espectral para cada tasa de muestreo mencionada anteriormente. Nótese que el desempeño de los algoritmos centroide y ajuste polinomial se ve fuertemente afectado cuando hay menos de 3 puntos en la zona del peak espectral, mientras que el algoritmo GPR prácticamente no presenta alteraciones en su nivel de precisión. Esto se condice con lo presentado en [27], donde se demuestra la robustez de la regresión basada en procesos gaussianos frente a diferentes muestreos espectrales. Por otra parte, en la figura 4.6-(b) se muestra la incertidumbre de los algoritmos calculada para diferentes pasos de muestreo, donde se aprecia un comportamiento similar al del *offset* pero en una escala mucho menor, debido a la ausencia de ruido en estos espectros. Debido a estos bajos valores, se podría concluir que en este caso la incertidumbre es prácticamente nula.

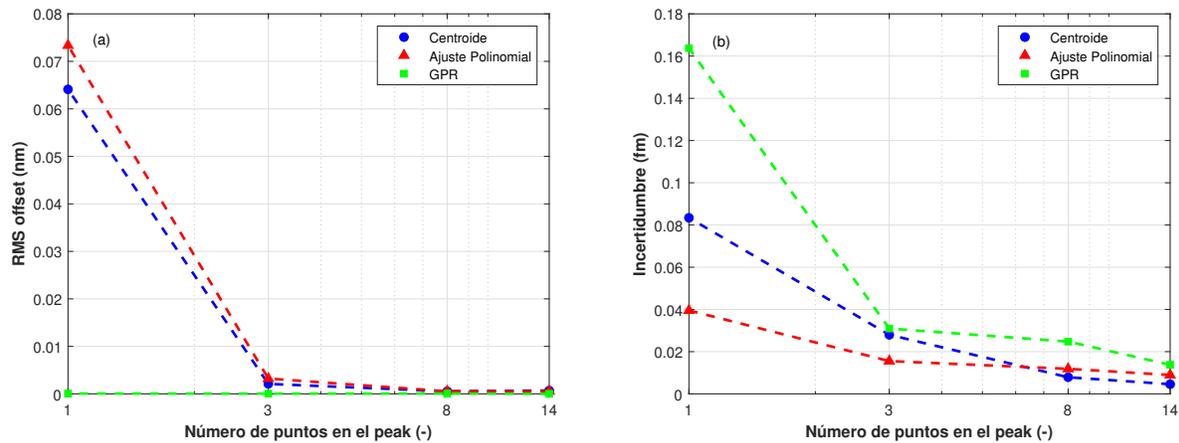


Figura 4.6: Resultados de (a) *offset* RMS y (b) incertidumbre vs muestreo espectral con datos simulados, sin ruido agregado.

#### 4.2.2 Resultados con datos experimentales

A continuación se estudia el desempeño de los diferentes algoritmos utilizando datos experimentales con diferentes niveles de atenuación. En la figura 4.7-(a) se muestran los valores calculados de *offset* RMS para atenuaciones desde los 0 hasta 39 dB, donde se observa una clara tendencia al alza para todos los algoritmos a medida que aumenta la atenuación. En el caso del GPR, su desempeño es ligeramente mejor que los demás algoritmos cuando la atenuación se mantiene bajo 27 dB, creciendo exponencialmente a partir de ese punto. Esto se explica por la dependencia que tienen las predicciones realizadas por el algoritmo frente a la forma espectral de los datos, la cual se va distorsionando con respecto a la forma de los datos de entrenamiento al aumentar la atenuación, como se puede ver en la figura 3.7. Los algoritmos centroide y ajuste polinomial presentan una mejor precisión que el GPR en altas atenuaciones, debido principalmente a que no requieren de una similitud entre los datos de entrenamiento y de testeo, y hacen uso principalmente de los puntos espectrales con mayor amplitud. A pesar de esto, su desempeño si se ve afectado por las deformaciones que sufren los espectros en altos niveles de atenuación, como por ejemplo pequeñas asimetrías de su forma espectral.

En la figura 4.7-(b) se muestra la incertidumbre de los algoritmos frente a los diferentes niveles de atenuación. Se puede observar que si bien existe una variación en los valores calculados, esta es despreciable (mucho menor a un orden de magnitud de diferencia), por lo cual es seguro concluir que la incertidumbre se mantiene prácticamente constante al variar la atenuación de las mediciones realizadas. De igual manera, si bien la incertidumbre calculada para el algoritmo GPR es mayor que la de los demás métodos, la diferencia entre las incertidumbres también puede considerarse como despreciable.

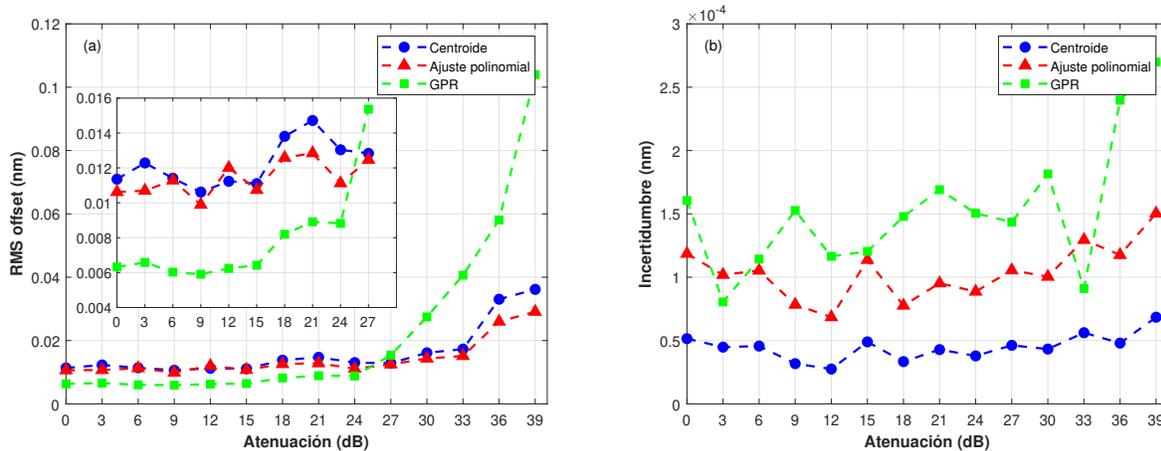


Figura 4.7: Resultados de (a) *offset* RMS y (b) incertidumbre vs atenuación con datos reales.

La figura 4.8-(a) muestra el *offset* RMS frente a la cantidad de puntos en el peak, variando desde 1 a 110 puntos. Por la FBG utilizada, de 1.1 nm de ancho espectral, estos números de puntos corresponden a muestreos entre 10 pm y 100 pm. Se puede observar que el centroide y el ajuste polinomial presentan altos niveles de error en configuraciones con bajo número de puntos en la zona del peak, lo que guarda cierta concordancia con lo presentado en la figura 4.6, donde también hay altos niveles de error en bajos muestreos espectrales. De igual manera, el GPR es altamente robusto a la cantidad de puntos en la zona del peak, a excepción de cuando hay 1 solo punto, escenario en el cual es de esperar que el algoritmo falle. Esto se asemeja bastante al comportamiento descrito en [27] y lo obtenido en la sección anterior, donde con datos simulados se obtienen resultados similares al analizar la robustez del GPR frente a diferentes pasos de muestreo espectral.

Por otra parte, en la figura 4.8-(b) se muestra la incertidumbre calculada para los algoritmos al variar la cantidad de puntos en la zona del peak espectral. Se puede notar que al igual que en el análisis anterior, la incertidumbre se mantiene prácticamente constante. Si bien existen algunas variaciones en los valores calculados, éstas son despreciables ya que son mucho menores a un orden de magnitud.

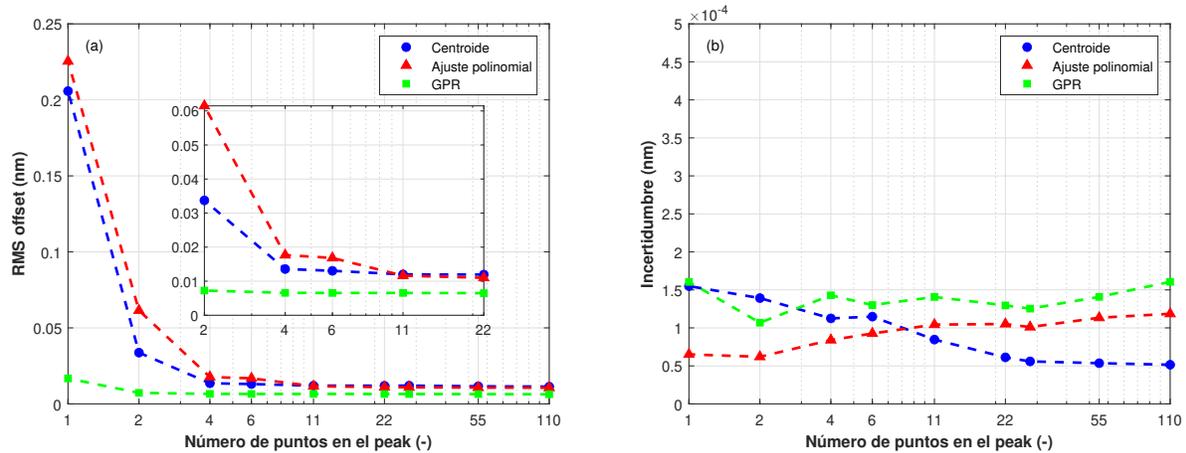


Figura 4.8: Resultados de (a) *offset* RMS y (b) incertidumbre vs puntos en la zona del peak con datos reales.

### 4.2.3 Comparación de desempeño de los algoritmos

A partir de los resultados mostrados anteriormente, es claro que en algunos de los escenarios planteados el algoritmo GPR presenta un mejor desempeño que los algoritmos centroide y ajuste polinomial, sobre todo en cuanto a su robustez frente a los diferentes muestreos espectrales o cantidad de puntos en la zona del peak espectral. Cabe mencionar que en situaciones donde la forma espectral es distorsionada, por ejemplo cuando las mediciones presentan mucho ruido o atenuación, el desempeño del GPR es ligeramente peor que el de los demás algoritmos, siendo éste su mayor inconveniente observado. También se puede notar una diferencia en el orden de magnitud de las incertidumbres calculadas para los análisis con datos simulados y experimentales, lo que se puede explicar en base a que las mediciones experimentales presentan variaciones en su valor de longitud de onda de Bragg, las cuales pueden estar afectando este cálculo.

## Capítulo 5

# Aplicación de sensores FBG en proceso de liofilización de alimentos

En este capítulo se investiga la factibilidad del uso de sensores FBGs para la medición de temperaturas en el contexto del proceso de liofilización de alimentos, la cual es una técnica de conservación basada en el secado de un producto a través de la sublimación del agua contenida en éste [29]. Un proceso estándar de liofilización consta de tres etapas: congelación del producto, secado primario y secado secundario. Durante la congelación el agua contenida en el alimento se transforma en hielo, el cual es sublimado (es decir, pasa directamente de estado sólido a estado gaseoso) durante el secado primario, etapa en la cual la presión del sistema se reduce a valores muy bajos (del orden de los milibares) y se le entrega energía al alimento elevando su temperatura con algún tipo de calentador. Si bien la liofilización es reconocida como uno de los mejores métodos de secado de alimentos (debido a que permite mantener las propiedades nutritivas del producto) [30], es también un procedimiento sumamente complejo, lento y costoso. Por esta razón, es importante realizar avances que permitan una mayor eficiencia de este proceso.

El parámetro más crítico dentro de la liofilización es la temperatura del producto [29], por lo cual el monitoreo de esta variable es de suma importancia. Tradicionalmente se han empleado sensores de temperatura basados en termocuplas tipo T u otras tecnologías, que si bien son capaces de leer correctamente la temperatura, suelen tener una serie de desventajas, tales como necesitar de una corriente eléctrica para realizar la medición (lo que puede generar transferencia térmica hacia el producto), emplazamiento invasivo, baja resolución (cercana a  $0.1^{\circ}\text{C}$  en termocuplas típicas), riesgo de corrosión, entre otras. Por esta razón, se propone el uso de sensores FBG, que además de presentar una mayor resolución y precisión que los típicos sensores utilizados, permiten el uso de multiplexación por división de longitud de onda (WDM), con lo cual se pueden inscribir múltiples sensores en un solo cable de fibra óptica. Además, las bajas dimensiones de la fibra posibilitan una instalación mucho menos invasiva que en el caso de las termocuplas. De esta manera, se puede medir la evolución de la temperatura en diferentes posiciones espaciales de forma sencilla. Cabe mencionar que para medir temperatura con los sensores FBG se requiere de un proceso de calibración previo que permita conocer la relación entre los cambios de longitud de onda de Bragg y la correspondiente temperatura del sensor. A continuación se describen los fundamentos teóricos y el procedimiento práctico de calibración realizado para el uso de sensores FBG en

el proceso de liofilización de alimentos, además del análisis de una medición de la etapa de secado primario realizada para evaluar la factibilidad de este planteamiento.

## 5.1 Calibración de sensores FBG

### 5.1.1 Fundamentos y consideraciones

Como se menciona en el marco teórico de este trabajo, lo que hace útil a las FBG como sensores es la relación que existe entre los cambios de longitud de onda de Bragg y los cambios de temperatura y/o strain, relación descrita por la ecuación 2.5. Si se asume que no hay variaciones de strain, esta expresión se puede reducir a  $\Delta\lambda = k_T\Delta T$ , donde  $k_T$  denota la sensibilidad del sensor a los cambios de temperatura [1, 2]. Para poder utilizar una FBG como sensor de temperatura es imperativo conocer el valor de esta sensibilidad, para lo cual es necesario realizar un procedimiento de calibración que permita relacionar los valores de longitud de onda de Bragg leídos por el esquema de interrogación y la temperatura de referencia correspondiente.

El procedimiento de calibración requiere de dos mediciones llevadas a cabo de forma simultánea: la longitud de onda de Bragg del sensor, y la temperatura a la que está sometido éste. En este caso, la longitud de onda es registrada con el interrogador de FBGs, mientras que la temperatura se mide con una termocupla independiente conectada a un convertidor análogo-digital. Con estos datos se puede realizar un proceso de regresión matemática para conocer el valor de la sensibilidad descrita anteriormente. Ahora bien, esta sensibilidad es más bien un concepto generalizador, puesto que la relación entre longitud de onda y temperatura puede no ser lineal como se ha descrito hasta ahora, principalmente en rangos amplios de temperatura y strain, siendo en realidad un función que puede ser obtenida por una regresión polinomial de orden superior. En estos casos, la regresión realizada permite conocer los valores de los parámetros de estas funciones que relacionan la temperatura y longitud de onda, descritos en la ecuación 5.1 por los valores  $a_1$ ,  $a_2$  y  $a_3$ .

$$\text{Regresión cuadrática: } T = a_3\lambda_B^2 + a_2\lambda_B + a_1 \quad - \quad \text{Regresión lineal: } T = a_2\lambda_B + a_1 \quad (5.1)$$

Para que las mediciones realizadas por los sensores sean válidas, éstos deben estar calibrados en el mismo rango de temperatura en el que serán utilizados. En este caso, la aplicación para la cual se usan estos sensores (es decir, la liofilización) presenta temperaturas que varían desde los  $-40^\circ\text{C}$  a  $40^\circ\text{C}$ , aproximadamente. En este caso, debido a limitaciones experimentales, se decide dividir las mediciones de calibración en dos etapas: altas (sobre temperatura ambiente) y bajas temperaturas (bajo temperatura ambiente). De esta forma se realiza una calibración entre el rango de temperaturas necesario. La sección de altas temperaturas consiste de mediciones registradas con el esquema mostrado en la figura 5.1, donde la FBG y la termocupla están posicionadas dentro de un vaso precipitado lleno de agua, el cual a su vez está dispuesto sobre un calefactor utilizado para elevar la temperatura del sistema. Cabe destacar que ambos sensores deben estar lo más cerca posible uno del otro, de forma que la temperatura del agua en sus posiciones sea lo más parecida posible.

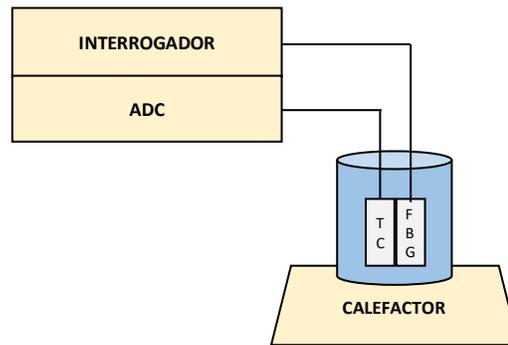


Figura 5.1: Esquema de medición en altas temperaturas

Por otro lado, las mediciones en bajas temperaturas son registradas con el esquema mostrado en la figura 5.2, en el cual la termocupla y el sensor FBG se disponen dentro de un vaso precipitado lleno de agua en un supercongelador, capaz de congelar el agua hasta aproximadamente  $-38\text{ }^{\circ}\text{C}$  en un periodo acotado de tiempo. En este caso ambos sensores también deben ser ubicados en la misma posición, tanto en altura como en ubicación radial, de forma que la temperatura sea igual para ambos elementos.

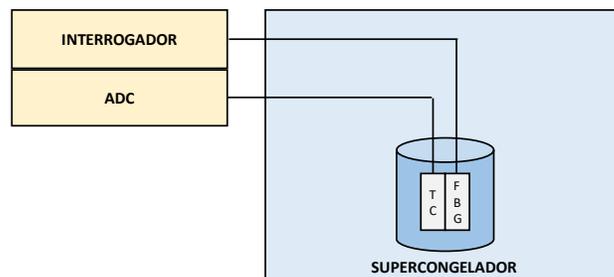


Figura 5.2: Esquema de medición en bajas temperaturas.

En la figura 5.3 se pueden ver las temperaturas registradas por las termocuplas en ambas etapas junto con las correspondientes longitudes de onda de Bragg recolectadas por el interrogador. Se puede apreciar como la evolución de ambas mediciones es similar, lo que da cuenta del correcto funcionamiento de los sensores FBG. Cabe notar que la sección de altas temperaturas se extiende más allá del rango requerido, de forma que se pueda tener algo de holgura en las mediciones finales. A partir de estos datos se ajusta una función polinomial utilizando la función *fit* de Matlab, junto con la función *fittype* para seleccionar el tipo de ajuste a realizar (lineal con un offset o cuadrático). De esta manera se obtienen los parámetros del polinomio ajustado, con los cuales posteriormente se pueden obtener nuevos valores de temperatura a partir de nuevas mediciones de longitud de onda realizadas con el sensor FBG. Cabe destacar que estas mediciones se hicieron para 4 arreglos de FBGs, compuestos de 10 sensores cada uno, pero para no sobrecargar el análisis descrito a continuación solo se muestran los resultados de un único sensor.

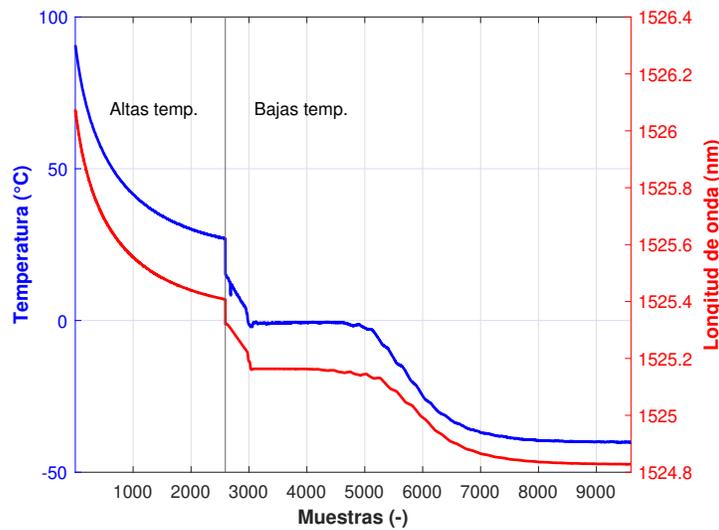


Figura 5.3: Temperaturas y longitudes de onda de Bragg medidas en el rango completo de temperaturas.

### 5.1.2 Proceso de calibración

A partir de la regresión polinomial aplicada a los datos recolectados se obtienen los parámetros mostrados en el cuadro 5.1, donde se detallan los resultados para el ajuste con función polinomial y función lineal (afín). De este último caso se puede destacar que la pendiente tiene un valor cercano a los 110 ( $^{\circ}\text{C}/\text{nm}$ ), lo que se condice con lo mencionado en el capítulo 3, donde se indica que existe una relación entre los cambios de temperatura y de longitud de onda cercana a 0.01 ( $\text{nm}/^{\circ}\text{C}$ ). Sin embargo, como se puede apreciar en la figura 5.4, los datos registrados no se ajustan de buena manera a una línea recta, o al menos no en el extenso rango de temperaturas utilizado. Esta imagen presenta las longitudes de onda comparadas con la temperatura de referencia a la que fueron registradas, junto con la curva lineal (afín) ajustada a estos datos.

Tipo de ajuste	Valor parámetros		
	$a_1$	$a_2$	$a_3$
Lineal (afín)	-170197.6	111.6	-
Cuadrático	-31910493.4	41731.1	-13.6

Cuadro 5.1: Parámetros de los polinomios ajustados a los datos registrados

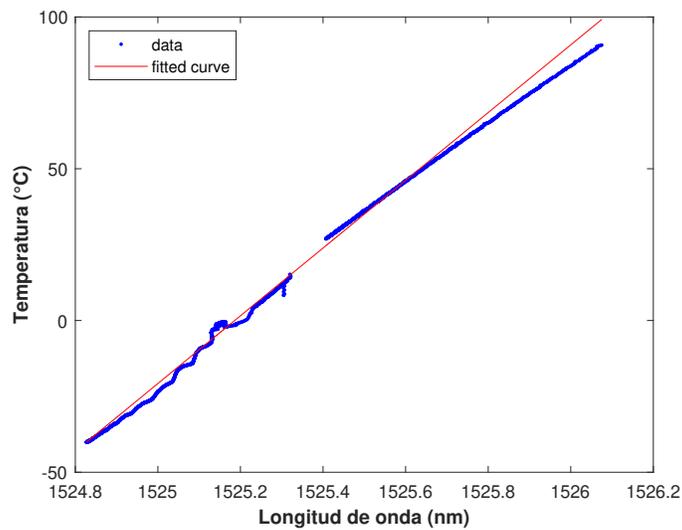


Figura 5.4: Temperatura vs longitud de onda y curva lineal (afín) ajustada por nueva calibración.

La figura 5.5 muestra que la curva cuadrática generada a partir de la regresión se ajusta de buena manera a los datos registrados, razón por la cuál se utiliza este polinomio en vez del ajuste lineal (afín). Cabe destacar que hay un rango de temperaturas entre aproximadamente 15 y 20 °C donde no fue posible registrar mediciones, debido a imposibilidades prácticas. En cualquier caso, la regresión realizada también contempla una interpolación de los datos, minimizando el efecto de falta de información en este rango de temperaturas.

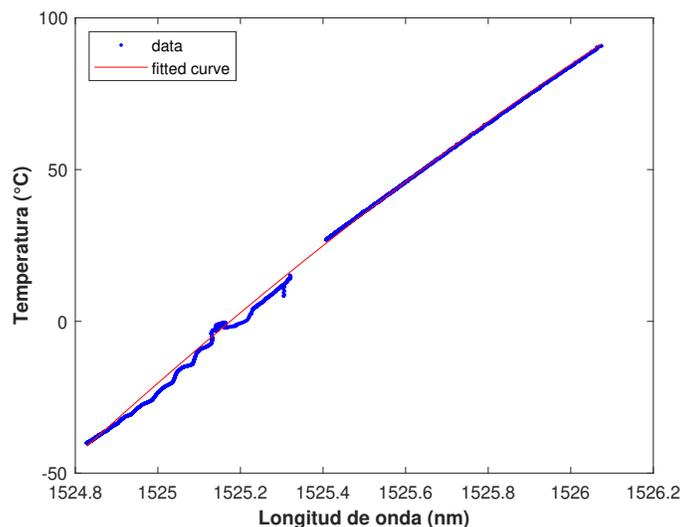


Figura 5.5: Temperatura vs longitud de onda y curva cuadrática ajustada.

Es importante mencionar que los sensores utilizados en esta aplicación traen consigo una calibración de fábrica, consistente de 10 puntos equidistantes en temperatura en un rango desde los -40 a los 40 °C, exhibida en la figura 5.6. En un principio, al ser tan pocos puntos, esta calibración se considera insuficiente, a pesar de que representa completamente el rango

de temperaturas necesarias. Sin embargo, los valores de los parámetros obtenidos a partir de este conjunto de datos son bastante similares a los resultantes de la calibración descrita anteriormente, lo que se puede apreciar en el cuadro 5.2. En esta tabla se comparan dichos parámetros y se puede observar que la diferencia entre ellos es menor a un 50% en todos los casos, lo que da cuenta de que el polinomio y también las futuras lecturas sobre nuevos datos serán bastante similares.

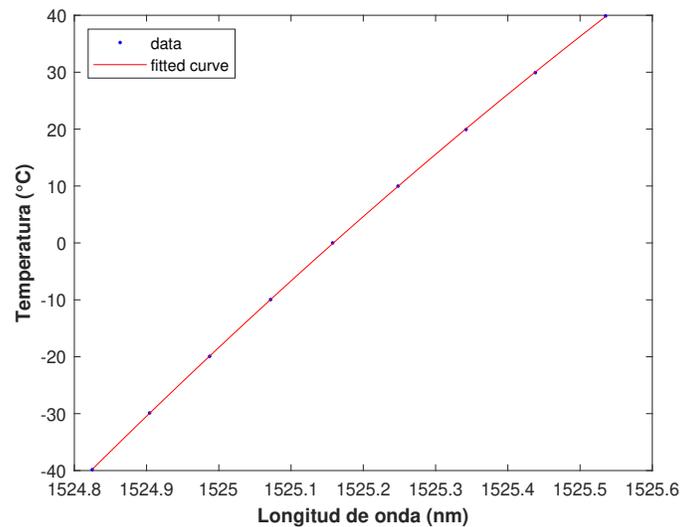


Figura 5.6: Datos de temperatura vs longitud de onda y curva ajustada de calibración original.

Valor parámetros			
Calibración	$a_1$	$a_2$	$a_3$
Experimental	-31910493.4	41731.1	-13.6
Fábrica	-44727187.5	58539.7	-19.2

Cuadro 5.2: Comparación de los parámetros resultantes de las calibraciones con datos de fábrica y datos registrados experimentalmente.

Para comprobar el buen funcionamiento de la calibración realizada, en la figura 5.7 se muestran las temperaturas calculadas a partir de las longitudes de onda de Bragg y los polinomios obtenidos con la calibración. Además, se muestra la temperatura de referencia medida por las termocuplas. Es claro como las temperaturas obtenidas a partir de la FBG son muy similares a las de referencia, con un ligero nivel de error que es casi despreciable. En la figura se exhibe también la temperatura calculada a partir de la calibración de fábrica, la cual en concordancia con lo descrito anteriormente, presenta un comportamiento similar al de la calibración realizada con las mediciones. Además, el *offset* RMS entre los valores de temperatura de referencia y los entregados por cada calibración son calculados según la expresión 3.1, resultando en un error de 1.35°C y 2.16°C para la calibración experimental y de fábrica, respectivamente. A partir de estos valores es posible asumir que ambos procedimientos

de calibración entregan resultados similarmente satisfactorios, debido al bajo error que se detecta entre los valores de temperatura calculados y los de referencia.

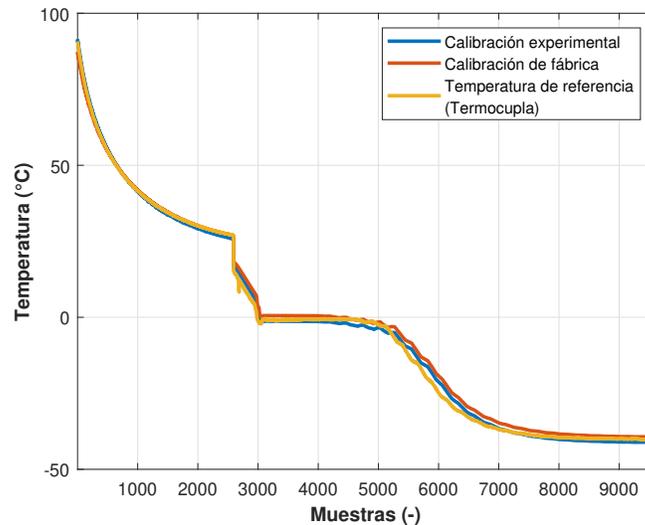


Figura 5.7: Comparación entre las temperaturas calculadas con la calibración de fábrica y la calibración experimental, junto con la temperatura de referencia.

## 5.2 Mediciones realizadas en proceso de liofilización

En esta sección se describe el procedimiento y los resultados obtenidos de las mediciones de la etapa de secado primario del proceso de liofilización de un alimento triturado (compota de fruta). Las mediciones fueron realizadas bajo el esquema de la figura 5.8, el cual muestra un grupo de termocuplas (TC) y un arreglo de sensores FBG dentro de un vaso precipitado lleno de agua, dispuesto sobre un plato calentador dentro del liofilizador. Este plato, que es parte del equipo liofilizador, contiene la conexión necesaria para medir la temperatura con las termocuplas y se encarga de calentar el producto para conseguir la sublimación del agua en su interior. Por otra parte, el arreglo de FBGs está compuesto por 10 sensores FBG de un largo de 3 mm cada uno, dispuestos cada 3 mm en formato *edge-to-edge* (es decir, entre el extremo de dos sensores FBG consecutivos hay 3 mm de distancia). Es importante mencionar que la medición en realidad fue llevada a cabo utilizando 3 arreglos de FBGs, pero por simplicidad de la figura solo se muestra uno de ellos. Los sensores poseen un recubrimiento de acero inoxidable, cuyo objetivo es brindar protección y firmeza para facilitar la inserción del arreglo en las muestras de alimentos. Los sensores además están multiplexados en longitud de onda (WDM: wavelength division multiplexing) de forma tal que cada reflexión espectral se genera en un rango de longitudes de onda diferente. Como se puede ver en la imagen 5.9, el primer sensor genera una reflexión espectral centrada en 1525 nm, mientras que la reflexión del segundo sensor se centra en 1530 nm, y así cada 5 nm hasta llegar a 1570 nm para el sensor número 10. En este caso, el primer sensor se refiere a aquel que está más alejado del extremo final del arreglo. Cabe destacar que este arreglo de FBGs es conectado al interrogador a través de un cable de fibra óptica que pasa por los orificios que posee la parte superior del vidrio del liofilizador. Este equipo debe operar en condición de vacío, por

lo cual estos orificios deben además ser tapados con algún material que impida la entrada de aire.

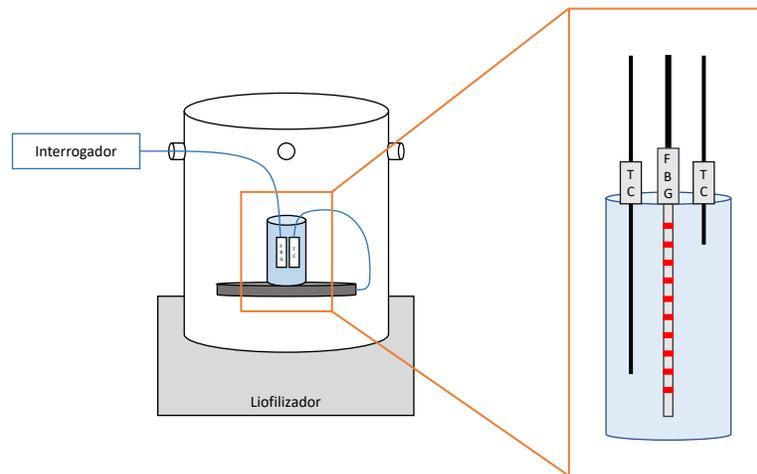


Figura 5.8: Esquema de medición en liofilizador.

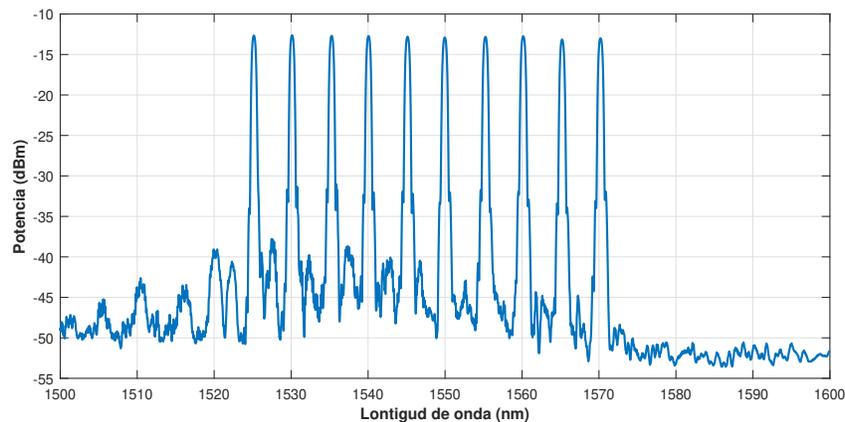


Figura 5.9: Reflexión espectral generada por el arreglo de FBGs utilizado.

La figura 5.10 muestra el resultado de las mediciones del procedimiento de liofilización realizado para solo un arreglo de 10 sensores FBG (líneas segmentadas). En esta imagen se puede apreciar que la temperatura sufre diversas variaciones a lo largo del tiempo para finalmente establecerse y tender a una temperatura final y estable, la cual coincide con la temperatura del plato calefactor (aprox. 30 °C). Es posible notar también que cada sensor FBG presenta una temperatura diferente a lo largo del tiempo. Esto se debe a que los sensores están distribuidos espacialmente de forma perpendicular al plato calefactor, lo que produce una mayor cercanía a éste por el sensor número 10, mientras que el número 1 es el más alejado de la fuente de calor. De esta manera, debido a la forma en que el calor avanza por el alimento (se produce un fenómeno denominado frentes de sublimación), los sensores más cercanos al plato presentan una temperatura más elevada en las primeras horas de la medición que los que están más alejados. Es importante

destacar que antes de iniciar la medición el alimento fue congelado y luego puesto a temperatura ambiente por algunos minutos, razón por la cual la temperatura inicial es cercana a 0°C.

La figura 5.10 también muestra los valores de temperatura registrados por las termocuplas (líneas gruesas), dispuestas de forma espacialmente distanciada, siendo la termocupla 1 la más alejada del plato calefactor, mientras que la número 3 la más cercana. Se puede notar que el comportamiento de las temperaturas recolectadas por las termocuplas es similar en su evolución a las registradas por las FBGs, con lo que se puede concluir que el uso de los sensores FBG en esta aplicación es factible. Sin embargo, también es apreciable una discrepancia entre los valores entregados por los diferentes equipos, lo que se puede atribuir a la diferencia en altura o distancia a la fuente de calor que existe entre estos sensores. En la práctica se hace sumamente difícil lograr que tanto la termocupla como uno de los sensores FBG estén exactamente a la misma altura y posición radial, por lo que siempre existirán ligeras diferencias entre los valores de temperatura registrados.

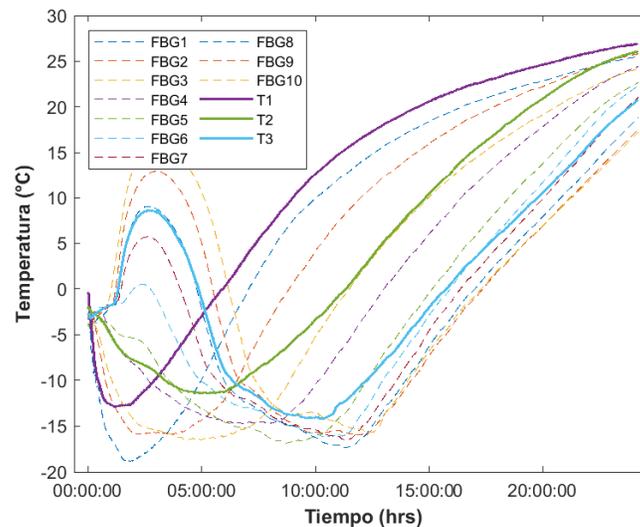


Figura 5.10: Evolución de la temperatura del proceso de liofilización, registrada con un arreglo de FBGs y 3 termocuplas situadas en diferentes posiciones espaciales.

Finalmente, la figura 5.11 muestra la comparación entre la evolución de las temperaturas registradas por cada termocupla y aquellas FBGs que estén ubicadas de la forma más cercana posible. Esta cercanía espacial tiene como objetivo que las temperaturas tengan mayor similitud, debido a que la temperatura evoluciona de forma diferente al variar la posición de la medición con respecto al plato calentador. Así, la termocupla 1 está asociada al primer sensor de cada arreglo de FBGs, la termocupla 2 al sensor número 3, y la termocupla 3 al octavo sensor. Los sensores son dispuestos de esta forma para conocer el comportamiento de la temperatura en diferentes posiciones espaciales. Se puede apreciar como la variación de temperatura en los 3 casos mostrados tiene un comportamiento bastante similar tanto para las termocuplas como para las FBGs, con ligeras discrepancias que pueden deberse a las diferencias en la posición en la que son instalados los sensores. Esta concordancia permite concluir nuevamente respecto a la factibilidad del uso de sensores FBGs en el proceso de liofilización.

En base a los resultados expuestos, se puede concluir que los sensores FBGs son capaces de registrar de forma satisfactoria los valores de temperatura en un procedimiento de liofilización de alimentos. Este procedimiento requiere de una calibración previa para realizar estas mediciones correctamente, la cual puede ser llevada a cabo con los datos entregados por el fabricante o a partir de una serie de mediciones realizadas según el método descrito en la sección anterior. Debido a los buenos resultados obtenidos en las mediciones mostradas, y la capacidad de ser multiplexados espectralmente y ubicar varios sensores en diferentes posiciones espaciales, las FBGs constituyen una excelente alternativa en la medición de temperatura en este tipo de tratamiento de alimentos.

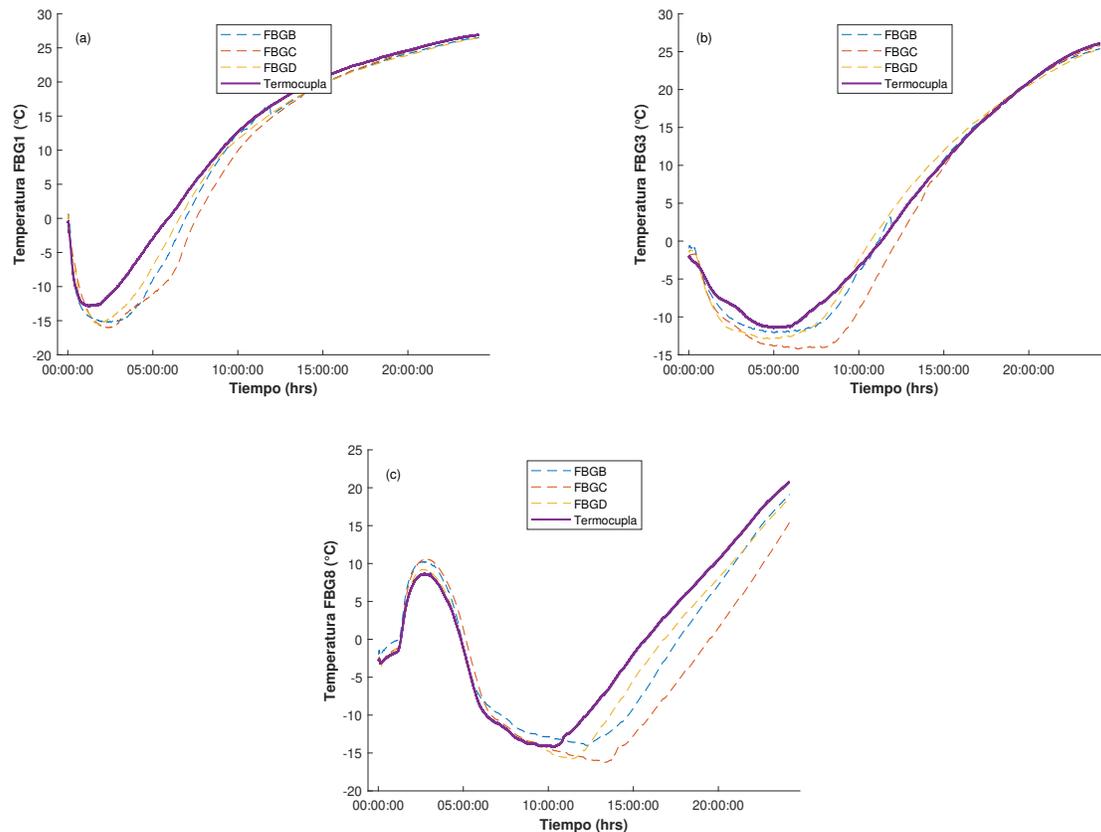


Figura 5.11: Evolución de la temperatura del proceso de liofilización, mostrada independientemente para cada termocupla acompañada por las temperaturas registradas por las FBGs situadas lo más cerca posible. (a) Termocupla 1 - FBG1, (b) Termocupla 2 - FBG3, (c) Termocupla 3 - FBG8.

## Capítulo 6

# Conclusiones

En el presente trabajo se han logrado implementar diferentes algoritmos de detección de peaks en el contexto de interrogación de sensores FBG. Entre los algoritmos revisados se encuentran el centroide, el ajuste polinomial y el novedoso algoritmo de regresión basada en procesos gaussianos (GPR), cuyos desempeños fueron analizados y comparados bajo diferentes condiciones de atenuación, ruido y muestreo espectral de los datos recolectados a partir de mediciones y de simulaciones. Los resultados muestran que el GPR tiene una mayor robustez que los demás algoritmos, sobre todo cuando se utilizan pocas muestras espectrales. Sin embargo, en situaciones donde la forma espectral se ve distorsionada, por ejemplo cuando las mediciones presentan altos niveles de ruido o atenuación, el desempeño del GPR se ve fuertemente afectado ya que este esquema depende de la similitud que hay entre los datos utilizados para su entrenamiento y posterior validación. Por otro lado, cuando hay poca atenuación o ruido, el funcionamiento de los demás algoritmos es ligeramente peor que el del GPR, lo que da cuenta de su buen rendimiento en la detección de peaks espectrales. Cabe destacar además como la incertidumbre o estabilidad de todos estos algoritmos se mantiene prácticamente constante en todos los escenarios planteados.

El desempeño de la regresión basada en procesos gaussianos en la detección de temperaturas fue analizado en profundidad en distintos escenarios, tales como diferentes niveles de atenuación de los espectros, variadas resoluciones espectrales, pasos de entrenamiento y también frente a variaciones de temperatura. Este análisis permite conocer los límites funcionales del algoritmo, además de sus limitaciones prácticas. Como se mencionó anteriormente, el GPR es fuertemente sensible a las diferencias entre las formas espectrales utilizadas para entrenar y las de validación, razón por la cual es imperativo que el algoritmo sea usado en circunstancias de baja atenuación o ruido, de lo contrario se observarán grandes errores en los resultados. Cabe destacar que es posible generar modelos para diferentes formas espectrales, con lo cual los errores podrían minimizarse a costa de un esquema de entrenamiento más complejo. A pesar de la sensibilidad del algoritmo frente a la atenuación, los resultados muestran que se podrían detectar temperaturas correctamente a una distancia de hasta 50 km desde el sistema de interrogación. Por otra parte, se ha verificado la extraordinaria robustez del GPR frente al muestreo espectral, lo que convierte a este algoritmo en una viable alternativa para sistemas de interrogación utilizando pocos puntos espectrales.

Las limitaciones del GPR también fueron estudiadas a partir de su desempeño frente a

la temperatura y rangos de entrenamiento. Los resultados permiten concluir que para un correcto funcionamiento del algoritmo, el rango de temperaturas con el que es entrenado debe ser igual o mayor que el rango con el que el algoritmo será utilizado. Altos niveles de error se observarán para temperaturas fuera de este rango. Además, dependiendo del paso de entrenamiento usado (vale decir, el salto de temperatura que hay entre cada dato utilizado para entrenar el algoritmo) puede generarse un sobreajuste del modelo, lo cual lleva a un mayor nivel de error de los resultados. Para evitar esto es necesario hacer un ajuste en el tamaño del conjunto de entrenamiento, lo cual también trae consigo un beneficio en cuanto a la reducción de los tiempos de cómputo. En este trabajo también se introdujo un novedoso esquema de entrenamiento basado en el desplazamiento digital de las mediciones espectrales. Los resultados muestran que el desempeño de este método es sumamente similar al del entrenamiento basado en mediciones experimentales, a partir de lo cual se verifica su utilidad y robustez. Este enfoque permite facilitar el entrenamiento del algoritmo y también agilizar la recolección de datos necesarios.

Finalmente, se estudió el proceso de calibración de sensores FBG en el contexto de liofilización de alimentos. Los resultados obtenidos demuestran el buen funcionamiento de la calibración realizada, lo que se puede observar a partir de la comparación entre las temperaturas entregadas por los sensores y las de referencia entregadas por termocuplas tradicionales. Cabe destacar que a partir de los datos de fábrica se puede realizar una calibración cuyos resultados son muy similares a los obtenidos con la calibración realizada a partir de mediciones experimentales. Esto da cuenta de que no es necesario contar con tantos puntos para obtener buenos resultados en las mediciones de temperatura.

## 6.1 Trabajos futuros

Durante este trabajo de memoria se han identificado algunos temas que pueden resultar en un interesante trabajo futuro, dentro de los cuales destacan los siguientes:

- Experimentar con diferentes opciones en la implementación del algoritmo GPR, ya sean diferentes kernels, hiperparámetros, optimización del algoritmo, entre otros. Además, puede ser útil encontrar las configuraciones óptimas del modelo para diferentes escenarios de entrenamiento.
- En relación al punto anterior, se puede indagar en la implementación de múltiples modelos para diferentes formas espectrales, o en otras palabras, entrenar el algoritmo para cada valor de atenuación o ruido.
- También puede ser interesante estudiar más en profundidad los límites funcionales del algoritmo, buscando por ejemplo los rangos mínimos de temperatura con los cuales aún se obtengan resultados aceptables, o explorar la mínima cantidad de datos necesarios para el correcto entrenamiento del algoritmo.
- El punto culmine de esta investigación es llevar a cabo la implementación del algoritmo en tiempo real en un sistema de interrogación instalado en terreno.

# Bibliografía

- [1] Othonos A., Kyriacos K., David P., Mugnier A.: “Fibre Bragg Gratings”, Springer Series in Optical Sciences, pp. 189–269, 2006.
- [2] Tosi D.: “Review and Analysis of Peak Tracking Techniques for Fiber Bragg Grating Sensors”, *Sensors* 17, no. 10: 2368, 2017.
- [3] Erdogan T.: “Fiber grating spectra”, *Journal of Lightwave Technology* 15, pp. 1277-1294, 1997.
- [4] Meltz G., Morey W.W.: “Bragg grating formation and germanosilicate fiber photosensitivity”, *International Workshop on Photoinduced Self-Organization Effects in Optical Fiber*, 1991.
- [5] Kersey A. D., et al.: “Fiber grating sensors”, in *Journal of Lightwave Technology*, vol. 15, no. 8, pp. 1442-1463, 1997.
- [6] Patrick H., Gilbert S.L.: “Growth of Bragg gratings produced by continuous-wave ultraviolet light in optical fiber”, *Opt. Lett.* 18, pp. 1484-1486, 1993.
- [7] Liu Y., Williams J.A.R., Zhang L., Bennion I.: “Abnormal spectral evolution of fibre Bragg gratings in hydrogenated fibres”, *Opt. Lett.* 27, pp. 586-88, 2002.
- [8] Riant I., Haller F.: “Study of the photosensitivity at 193 nm and comparison with photosensitivity at 240 nm influence of fiber tension: type IIA aging”, *J. Lightwave Technol.* 15, pp. 1464-1469, 1997.
- [9] Archambault J. L., Reekie L., Russell P.St.J.: “High reflectivity and narrow bandwidth fibre gratings written by single excimer pulse”, *Electron. Lett.* 29, pp. 28-29, 1993.
- [10] Hill K.O., Theriault S., Malo B., Bilodeau F., Kitagawa T., Johnson D. C., Albert J., Takiguchi K., Kataoka T., Hagimoto K.: “Chirped in-fiber Bragg grating dispersion compensators: Linearization of the dispersion characteristic and demonstration of dispersion compensation in a 100 km, 10 Gbit/s optical fiber link”, *Electron. Lett.* 30, pp. 1755-1756, 1994.
- [11] Hill K.O., Fujii Y., Johnson D.C., Kawasaki B.S.: “Photosensitivity in optical fiber waveguides: Application to reflection filter fabrication”, *Appl. Phys. Lett.* 32, pp. 647-649, 1978.
- [12] Meltz G., Morey W.W., Glenn W.H.: “Formation of Bragg gratings in optical fibers by a transverse holographic method”, *Opt. Lett.* 14, pp. 823-825, 1989.

- [13] Dockney M.L., James J.W., Tatam R.P.: “Fiber Bragg grating fabricated using a wavelength tuneable source and a phase-mask based interferometer”, *Meas. Sci. Technol.* 7, 445, 1996.
- [14] Hill K.O., Malo B., Bilodeau F., Johnson F.C., Albert J.: “Bragg gratings fabricated in monomode photosensitive optical fiber by UV exposure thorough a phase-mask”, *Appl. Phys. Lett.* 62, pp. 1035-1037, 1993.
- [15] Malo B., Hill K.O., Bilodeau F., Johnson D.C., Albert J.: “Point-by-point fabrication of micro-Bragg gratings in photosensitive fiber using single excimer pulse refractive index modification techniques”, *Electron. Lett.* 29, pp. 1668–1669, 1993.
- [16] Bodendorfer T., Muller M., Hirth F., Koch A.: “Comparison of different peak detection algorithms with regards to spectrometric fiber Bragg grating interrogation systems”, *Proceedings of International Symposium on Optomechatronic Technologies (ISOT)*, Istanbul, Turkey, pp. 21–23, 2009.
- [17] Atkins C.G., Putnam M.A., Friebele E.J.: “Instrumentation for interrogating many-element fiber Bragg grating arrays”, *Proc. SPIE*, 2444, pp. 257–267, 1995.
- [18] Chen W., Vallan A.: “Applications of a Fast FBG Interrogation System for Real-Time Thermal and Structural Monitoring”, in *Proceedings of the IEEE 1st International Forum on Research and Technologies for Society and Industry: Leveraging a Better Tomorrow (RTSI)*, pp. 388–391, 2015.
- [19] Caucheteur C., Chah K., Lhomme F., Blondel M., Megret P.: “Autocorrelation demodulation technique for fiber Bragg grating sensor”, *IEEE Photonics Technol. Lett.* 2004, 16, pp. 2320–2322, 2004.
- [20] Gong J.M., MacAlpine J.M., Chan C.C., Jin W., Zhang M., Liao Y.B.: “A novel wavelength detection technique for fiber Bragg grating sensors”, *IEEE Photonics Technol. Lett.*, 14, pp. 678–680, 2002
- [21] Lamberti A., Vanlanduit S., de Pauw B., Berghmans F.: “A novel fast phase correlation algorithm for peak wavelength detection of fiber Bragg grating sensors”, *Opt. Express* 22, pp. 7099–7112, 2014.
- [22] Tosi D.: “KLT-based algorithm for sub-pm accurate FBG tracking with coarse wavelength sampling”, *Photonics Technol. Lett.* 27, pp. 2134–2137, 2015.
- [23] Tosi D.: “Improved KLT Algorithm for high-precision wavelength tracking of optical fiber bragg grating sensors”, *J. Sens.* 2017, 2017.
- [24] Paterno A.S., Silva J.C.C., Milczewski M.S., Arruda L.V.R., Kalinowski, H.J.: “Radial-basis function network for the approximation of FBG sensor spectra with distorted peaks”, *Meas. Sci. Technol.* , 17, pp. 1039–1045, 2006.
- [25] Rasmussen C.E., Williams C.K.I.: “Gaussian Processes for Machine Learning”, The MIT Press, 2006.
- [26] Wang J.: “An Intuitive Tutorial to Gaussian Processes Regression”, Ingenuity Labs Research Institute, 2021.

- 
- [27] Djurhuus M.S.E., Werzinger S., Schmauss B., Clausen A.T., Zibar D.: “Machine Learning Assisted Fiber Bragg Grating-Based Temperature Sensing”, *IEEE Phot. Technol. Lett.* 31(12), pp. 939-942, 2019.
- [28] Pal D., Kumar A., Gautam A., Thangaraj J.: “FBG Based Optical Weight Measurement System and Its Performance Enhancement Using Machine Learning”, *IEEE Sens. J.* 22(5), pp. 4113-4121, 2022.
- [29] Kasper J.C., Wiggenhorn M., Resch M., Friess W.: “Implementation and evaluation of an optical fiber system as novel process monitoring tool during lyophilization”, *European Journal of Pharmaceutics and Biopharmaceutics*, 83, pp. 449-459, 2013.
- [30] Ramírez-Navas J.: “Liofilización de alimentos”, *Revista ReCiTeIA*, 6, pp 1-39, 2007.