

Reconocimiento de patrones aplicando LDA y LR a señales optoelectrónicas de sistemas de barrido óptico

Miranda-Vega, J.E.^a, Rivas-López, M.^a, Flores-Fuentes, W.^{b,*}, Sergiyenko, O.^a, Lindner, L.^a, Rodríguez-Quiñonez, J.C.^b

^aUniversidad Autónoma de Baja California, Instituto de Ingeniería (Campus Mexicali), Blvd. Benito Juárez S/N, Parcela 44, 21280 Mexicali, BC, México.

^bUniversidad Autónoma de Baja California, Facultad de Ingeniería (Campus Mexicali), Blvd. Benito Juárez S/N, Parcela 44, 21280 Mexicali, BC, México.

To cite this article: Miranda-Vega, J.E., Rivas-López, M., Flores-Fuentes, W., Sergiyenko, O., Lindner, L., Rodríguez-Quiñonez, J.C.. Pattern Recognition by applying LDA and MRL to optoelectronic signals for optical scanning systems. Revista Iberoamericana de Automática e Informática Industrial 17, 401-400. <https://doi.org/10.4995/riai.2020.12385>

Resumen

Este artículo da seguimiento a previas experimentaciones actualmente publicadas acerca de la minimización de ruido óptico-eléctrico en los sistemas de barrido óptico OSS (en inglés, Optical Scanning Systems), implementando técnicas computacionales para el reconocimiento de los patrones que se generan de cada fuente de referencia y que son utilizadas para indicar una coordenada que el OSS monitoreará. Técnicas como análisis lineal discriminante LDA (en inglés, Linear Discriminant Analysis) y regresión lineal LR (en inglés, Linear Regression) fueron implementadas para discriminar las señales causadas por otras fuentes distintas a las de referencia. Para aumentar la eficiencia de estos modelos fueron implementados codificación predictiva lineal LPC (en inglés, Linear Predictive Coding) y Cuantiles como extractores de características. Los resultados fueron alentadores con tasas de reconocimiento mayores al 91.2 %, alcanzando en algunos casos una exactitud del 100 %.

Palabras clave: Análisis y tratamiento de señales, sensores e instrumentos virtuales, ruido, modulación, visión 3D y estéreo.

Pattern recognition applying LDA and LR to optoelectronic signals of optical scanning systems

Abstract

This paper is a follow-up to previous researches already published regarding the minimization of optical-electrical noise in optical scanning systems OSS, by the implementation of computational techniques for pattern recognition generated by each reference source used to indicate a coordinate that the OSS will be monitoring. Techniques such as linear discriminant analysis LDA and linear regression LR were implemented in order to discriminate the signals caused by other sources different to the references. In order to enhance the efficiency of these models was implemented linear predictive coding LPC and quantiles as features extractors. The results were encouraging with rates of recognition greater than 91.2 %, reaching in some cases an accuracy of 100 %.

Keywords: Analysis and treatment of signals, sensors and virtual instruments, noise, modulation, 3D stereo vision.

1. Introducción

El monitoreo de salud estructural SHM (en inglés, Structural Health Monitoring) es una disciplina que se centra principalmente en la evaluación de las condiciones de salud de estructuras como: vigas, armaduras, puentes, plataformas, estruc-

turas aeroespaciales, edificios, naves industriales, etc. Existen distintas tecnologías para monitorear características dinámicas tales como: vibraciones, desplazamientos o deformaciones que sufren las estructuras. Las tecnologías que más sobresalen para aplicaciones de SHM son aquellas basadas en: fibra óptica,

*Autor para correspondencia: flores.wendy@uabc.edu.mx

sistema de posicionamiento global GPS (en inglés, Global Positioning System), LiDAR (en inglés, Light Detection and Ranging), sistemas basados en cámaras de video y sistemas de barrido óptico OSS (en inglés, Optical Scanning Systems).

Por otro lado, la selección del tipo de tecnología depende principalmente del contexto de la aplicación (que sea apta para implementarla), y del costo de estos dispositivos o tecnologías.

Las aplicaciones basadas en fibra óptica son ampliamente usadas en áreas como: astronomía, espectroscopia, visión artificial, comunicaciones ópticas y cualquier otra aplicación donde se empleen señales ópticas. Las principales ventajas del uso de la fibra óptica son: la inmunidad a la interferencia electromagnética y sus pequeñas dimensiones.

Entre las desventajas del uso de fibra óptica para aplicaciones de SHM, se pueden mencionar las siguientes: en primer lugar que son invasivas, y en consecuencia la dificultad para su reparación cuando esta ha sido dañada, en segundo lugar el proceso de conversión de señales eléctricas a señales de luz y viceversa, debido a que se le pueden adherir señales eléctricas no deseadas, finalmente el costo de instalación y de mantenimiento. Estas desventajas de la fibra óptica para aplicaciones de SHM pueden ser determinantes a la hora de tomar decisiones por parte del diseñador.

Por otra parte, la tecnología basada en GPS tiene algunas ventajas para tareas de SHM, como las siguientes: que pueden trabajar bajo condiciones climáticas adversas, además de que se puede medir el desplazamiento de una estructura en tres dimensiones (Cheng et al., 2002). Sin embargo, la precisión del GPS aún es insuficiente para las aplicaciones y requerimientos de SHM (Jo et al., 2013).

Otras tecnologías como los sistemas OSS también son implementadas para aplicaciones y tareas de SHM. Sin embargo, este tipo de tecnología cuyo principio de funcionamiento se basa en dispositivos optoelectrónicos como fotosensores y fuentes de radiación, puede ser usada en dos configuraciones diferentes, las cuales corresponden a un método activo y otro pasivo.

El método activo se lleva a cabo mediante el escaneo o barrido realizado con un láser, en este método el sistema OSS emplea su propia fuente de radiación de forma activa, es decir, que este es capaz de enviar la señal energética al objeto o estructura y posteriormente este sistema (activo) puede captar la señal reflejada por la superficie del objeto o la estructura.

El escaneo mediante el láser puede ser consultado en (Lindner et al., 2016), donde fue implementado para determinar las coordenadas en 3D de la posición de un robot móvil. La importancia del método activo reside en que el sistema puede controlar su propia fuente de radiación y también es posible obtener mediciones en cualquier momento del día, con el inconveniente que es de corto alcance.

Por otro lado, el método pasivo sirve para detectar la energía natural que es reflejada o que se emite desde el objeto o estructura observada (Jung and Park, 2018) a largo alcance. En (Sergiyenko et al., 2009) se puede explorar el método pasivo en el contexto de sistemas OSS. En ese mismo trabajo se utiliza este método el cual consiste en un escaneo óptico pasivo POS (en inglés, Passive Optical Scanning), el cual se basa en la exploración de puntos luminosos de referencia que son fijados a una estructura, plataforma u objeto bajo estudio. Para los sistemas OSS el uso de fuentes de radiación como puntos de referencia,

resulta ser menos costosa en comparación con el método activo, el cual está basado en dispositivos láser. La principal ventaja del método pasivo sobre el método activo, es que el método pasivo permite seleccionar un rango espectral del fotosensor y la fuente de referencia con la finalidad de minimizar la interferencia de otras fuentes de radiación en el ambiente real de operación, y de este modo aumentar el alcance de medición del sistema.

Un ejemplo de aplicación de SHM mediante sistemas POS puede ser una o varias fuentes de luz incoherente montadas en una estructura, las cuales pueden ser emitidas por un diodo emisor de luz LED (en inglés, Light Emission Diode) o una lámpara incandescente.

En el contexto de diseño de sistemas ópticos para determinar el nivel de daño de una estructura o desplazamiento basándose en los sistemas OSS pasivos, es importante mencionar que el sistema OSS pueda comparar de modo continuo las coordenadas calculadas a partir de los puntos de referencia montados sobre la estructura con parámetros específicos previamente contenidos en una base de datos, esto con la finalidad de poder predecir si existen cambios en las características dinámicas del objeto o estructura bajo estudio. En esta etapa de monitoreo es fundamental que se puede prevenir el riesgo de operar sobre una estructura que está dañada o que ya no cumple con los requerimientos de diseño, debido a que esta ya no es adecuada para ser utilizada de forma segura.

Otro de los aspectos que deben ser considerados para el diseño y desarrollo de aplicaciones basadas en OSS, son los fotosensores que se utilizan para captar la radiación de los puntos de referencia situados sobre las estructuras. Según (Doebbling et al., 1996), la selección del tipo, la ubicación del sensor y el procesamiento de la señal son cuestiones muy importantes a tener en cuenta en el diseño de un sistema de detección. Los datos proporcionados por los sensores son muy importantes para verificar si el daño está presente o no. Sin embargo, también es importante considerar que en la ejecución de aplicaciones de SHM es conveniente resolver un problema, como lo es la discriminación entre los efectos causados por los daños, y los efectos que son causados por las influencias operativas y ambientales (Van der Auweraer and Peeters, 2003).

Varios tipos de sensores utilizados para aplicaciones de SHM, como acelerómetros, sensor ultrasónico, sensores acústicos pasivos, y galgas extenso-métricas, son difíciles de implementar en estructuras grandes, además de que no pueden soportar ambientes hostiles y trabajar continuamente durante períodos largos de tiempo (Di Sante, 2015). En el caso de usar acelerómetros y sensores de tensión estos resultan ser muy costosos en instalación y en el sistema de adquisición requerido (Feng and Feng, 2017).

Para poder seleccionar el sensor del sistema es importante considerar, el tiempo de respuesta que este ofrece, ya que para medir características dinámicas como la vibración y el desplazamiento del objeto o estructura que está bajo estudio es imprescindible que el sensor ofrezca tiempos de respuesta en el orden de nanosegundos. Un ejemplo del tiempo de respuesta de los sensores piezoeléctricos se puede observar en los motores diésel donde estos son empleados (X.Ba et al., 2017), mientras que los artículos técnicos de Denso Corporation revelan que los resultados de estudios indican que la respuesta actual más corta de un inyector piezoeléctrico es de aproximadamente 100 μ s.

En el presente trabajo se presenta una alternativa para reducir el costo en implementación y minimizar los efectos causados por las influencias ambientales y así mismo obtener tiempos de respuesta menores de microsegundos (μs) y que se ajusten a los requerimientos de aplicaciones de SHM. Dicha alternativa es utilizar el dispositivo LED como transductor en el OSS en forma pasiva para captar los puntos de referencia colocados sobre estructuras para el estudio y adquisición de características dinámicas.

Una de las ventajas de emplear al LED como transductor es su alta disponibilidad en el mercado y su angosto rango espectral de operación. Esta última característica es muy importante, ya que este dispositivo es menos sensible a radiaciones que estén fuera de su rango espectral de operación y que se encuentren en el ambiente real. Los efectos de interferencia en el transductor del sistema OSS son provocados por otras fuentes de radiación naturales o artificiales, como podrían ser la luz solar o lámparas, respectivamente. Un LED utilizado como fotosensor bajo condiciones adversas como la exposición al medio ambiente ya ha sido implementado en otros trabajos como (Brooks and Mims III, 2001; Mims, 2000), obteniendo resultados interesantes que motivaron la presente investigación. En (Flores-Fuentes et al., 2018), se tiene el antecedente de realizar una comparación entre distintos tipos de transductores para el sistema OSS, en donde se incluye a un LED azul como fotosensor así como también un fototransistor, fotodiodo (OPT301) y una fotoresistencia LDR (en inglés, Light Dependent Resistor). Estos dispositivos fueron sometidos a pruebas tanto en laboratorio como en el ambiente real de operación. Los resultados revelaron que el LED azul y el fototransistor son menos sensibles a la radiación solar durante el experimento. Sin embargo, el uso de estos dispositivos como transductores en el sistema OSS, conlleva a otros problemas como el ruido opto-electrónico provocado por el proceso de amplificación de la pequeña señal de la fotocorriente generada por el LED, aunado a la susceptibilidad de interferencias que son causadas por realizar mediciones en ambientes no controlados. Para resolver estos problemas se aplican etapas de filtrado analógico o digital, sin embargo, mediante el filtrado también parte de la señal de interés será removida junto con el ruido lo cual tampoco es una buena opción.

En el presente trabajo se propone implementar herramientas y técnicas de aprendizaje automático (*machine learning*) para identificar las interferencias que son capturadas por el sistema OSS y que ocasionan que este determine erróneamente la posición angular de la fuente de referencia.

La estructura de este trabajo está integrada de la siguiente forma: en la primera sección se realiza una revisión del ruido e interferencia en el sistema OSS, luego se realiza una revisión de la etapa de adquisición de las señales optoelectrónicas.

La sección 2 está enfocada a la extracción de características de las señales. Luego en la sección 3 se muestra el esquema experimental que se utilizó para llevar a cabo la captura de las señales y de las observaciones.

En la sección 4 se describen los fundamentos teóricos del modelo LR y en la sección 5 se describen los fundamentos de LDA. Finalmente, en las secciones 6 y 7 se muestran los resultados y conclusiones de este trabajo respectivamente.

1.1. Ruido electro-óptico e interferencia de distintas fuentes de radiación:

Uno de los principales retos en el diseño de un sistema OSS es la minimización del ruido óptico y eléctrico, esto es con la finalidad de tener una mejor exactitud y precisión en las mediciones del sistema OSS. El ruido electro-óptico es causado por señales no deseadas e interferencias que se encuentran en el ambiente real de operación y que afectan el rendimiento de un sistema OSS. Estas señales no deseadas se producen por la combinación del ruido eléctrico y óptico en dispositivos como fototransistores, fotodiodos, lentes y espejos. La parte optoelectrónica del presente sistema óptico diseñado se encarga de convertir una señal de luz en una señal eléctrica y esta es realizada mediante un LED azul (fotosensor). En todos los sistemas basados en semiconductores, el ruido es un problema inherente y este puede ser provocado por distintos factores, entre los cuales se pueden mencionar los siguientes cuatro: como lo son el ruido eléctrico, el ruido térmico, el ruido de disparo y el ruido de intermitencia.

El LED como fotosensor implementado en el presente trabajo, no está exento de estos cuatro tipos de ruido. Este dispositivo usado como fotosensor genera una pequeña fotocorriente durante el proceso de captura de la señal óptica que es emitida por la fuente de referencia. Esta pequeña señal debe de ser amplificada y es en esta etapa de amplificación, en donde señales no deseadas pueden interponerse a la señal óptica de referencia. Esto implica que se susciten graves problemas en el momento en que el sistema OSS calcule la posición angular de la fuente de referencia.

En el caso del ruido óptico, este es causado por interferencia de fuentes distintas a la fuente de referencia, entre los principales factores que afectan el rendimiento del sistema OSS son los que se generan de manera natural como la radiación solar, ya que este abarca gran parte del espectro visible.

Cuando los sistemas OSS están expuestos ante la intemperie, factores como la humedad, lluvia, polvo generan otros problemas como dispersión y refracción de la luz y esto también afecta el monitoreo de la fuente de referencia. Además, de las fuentes naturales, también existen otras fuentes como el ruido que se genera por actividades de origen humano como: la contaminación del medio, la iluminación pública, la iluminación que es generada por los automóviles, la reflexión de espejos de edificios, parabrisas de los automóviles, entre otros ejemplos.

El sistema OSS en operación en ambiente real siempre está expuesto a la energía radiante de distintas longitudes de onda, y estas interfieren con los sensores optoelectrónicos del sistema. En (Miranda-Vega et al., 2019) se realizó un estudio sobre la aplicación de filtros digitales al LED azul con el objetivo de suavizar y atenuar la señal con ruido que es generado durante la etapa de amplificación. En este trabajo los filtros digitales FIR (en inglés, Finite Impulse Response) como Savitzky-Golay y filtros con ventanas Hamming permitieron reducir la problemática del ruido eléctrico. Sin embargo, una vez resuelto el problema del ruido eléctrico, en un ambiente real de operación es posible que sucedan interferencias como se muestran en la siguiente Figura 1, esta interferencia no se discrimina con filtros digitales ni con filtros analógicos, debido a que estas señales tienen la misma longitud de onda.



Figura 1: Señales captadas por el sistema OSS tanto para una fuente (señal Clase 1) como dos fuentes de radiación (señal Clase 2).

En la Figura 1 se muestran dos tipos de señales, en donde una corresponde a una sola fuente de referencia y esta en color azul, este tipo de señal es parecida a una gaussiana y para fines del presente trabajo será etiquetada como Clase 1. En el caso de la segunda señal que se ilustra en color rojo será etiquetada como Clase 2, la cual es generada cuando dos fuentes de radiación tienen la misma longitud de onda pero con distinta posición angular respecto a la posición del sistema OSS. En (Flores-Fuentes et al., 2014), (Rivera-Castillo et al., 2017), fue registrado que en ambiente real el sistema OSS disminuía su precisión en comparación de ambientes controlados (laboratorio), e inclusive que bajo ciertas condiciones ambientales es imposible tomar lecturas. La interferencia de dos o más fuentes de radiación causa problemas para el desempeño y rendimiento de sistemas OSS.

Para este tipo de situaciones es importante utilizar herramientas como LDA y LR para modelar cada patrón generado, y así poder discriminar cuál de las fuentes detectadas corresponde a la fuente de referencia, ya que esta es necesaria para determinar las coordenadas sobre la estructura estudiada.

1.2. Adquisición de la señal de un sistema OSS

El proceso de adquisición de la señal que se llevó a cabo para este trabajo desempeña un rol importante, debido a que la calidad de la señal capturada puede influir en la precisión del sistema óptico. Hay que resaltar que durante este proceso, el sistema OSS captura la señal y luego se realizan operaciones por una unidad de control, como una PC (en inglés, Personal Computer) para determinar si existe la presencia de un daño estructural o también se puede conocer el tiempo de vida que tiene una estructura.

En el presente artículo el sistema de barrido implementado consta de dos sensores para capturar señales optoelectrónicas. El primer sensor del sistema OSS consiste en un LED azul que es utilizado como transductor convirtiendo la señal radiante emitida por una fuente de referencia en una señal eléctrica. El procedimiento para captar esta señal radiante es el siguiente: en primer lugar, considerando que una señal radiante es montada sobre una estructura, esta última emite radiación y luego el sistema OSS capta la luz emitida mediante una apertura y posteriormente esta luz es reflejada por un espejo con corte a 45° hacia una lente biconvexa y posteriormente esta enfoca en el LED, para tener una mejor referencia, en la Figura 2 se ilustra

la fuente de referencia montada en una estructura y el sistema OSS y en la Figura 3 se muestran los elementos que componen al sistema OSS.

La adquisición de la señal del LED azul es procesada por un canal analógico de un DAQ modelo USB-6003 de National Instrument.



Figura 2: Fuente de referencia (circulo amarillo) montada en una estructura y el sistema óptico de barrido (circulo en rojo).

El segundo fotosensor utilizado por el sistema OSS corresponde a la señal capturada por un opto-interruptor que es colocado sobre el disco que sirve de soporte para el espejo a 45° . El disco tiene una perforación y cuando este gira, la sección sólida del disco obstruye el camino óptico del opto interruptor y así, cada vez que el disco realice una revolución completa este enviara un pulso y luego una compuerta Schmitt-Trigger recibe esta señal para después producir a la salida un nivel de tensión más estable para su posterior procesamiento por el sistema de adquisición.

El dispositivo DAQ (en inglés, Data Acquisition) utilizado tiene una resolución de 16 bits y permite 100,000 muestras por segundo, además también cuenta con dos canales de salida analógica de 5,000 muestras cada segundo. En el caso de entradas digitales cuenta con 13 canales y un contador de 32 bits. La frecuencia de muestreo que se utilizó para los experimentos fue de 50,000 muestras por segundo para cada canal, es decir en total fueron 2 canales utilizados. Para tener una mejor referencia de los elementos importantes del sistema OSS previamente descritos, (véase Figura 3). En esta figura se ilustra la apertura, el espejo, a 45° , el opto-interruptor utilizado ITR8102 y el disco con la perforación para medir el número de revoluciones del motor DC por cada segundo.

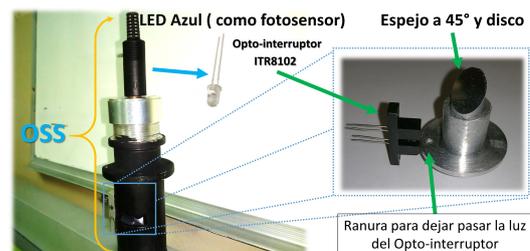


Figura 3: Elementos principales del sistema OSS

2. Extracción de características del conjunto de datos Clase 1 y Clase 2

Como se mencionó anteriormente, una vez que el sistema OSS entre en operación en un ambiente real, este es susceptible a interferencias de radiaciones que tienen la misma longitud de onda. Debido a esto es necesario discriminar las señales que corresponden a la fuente de referencia como de las que se adhieren por interferencia. Para lidiar con esto, se tratará como un problema de reconocimiento de patrones. Para ello se hace uso metodologías que son aplicadas en aprendizaje automatizado. Una de las etapas principales en que se basa esta rama de la inteligencia artificial, es la selección y extracción de características, ya que estas representan el conjunto de datos del caso de estudio.

La precisión en la extracción de características tiene una gran influencia en los resultados finales de la identificación (Cervantes et al., 2017). Además de mejorar el rendimiento de los clasificadores mediante la extracción de características, también es importante mencionar que debido a que la capacidad de memoria de los sistemas de procesamiento es finita, es necesario trabajar con las características más relevantes de una señal o de un conjunto de datos, y sobre todo que puedan modelar y describir el comportamiento. Esto con la finalidad de conservar las características propias de las señales originales bajo los requerimientos mínimos de memoria empleados por una unidad de control.

Entre los distintos tipos de extractores de características que existen se encuentran los LPC (en inglés, Linear Predictive Codes), MFCC (en inglés, Mel Frequency Cestral Coefficients), los PLP (en inglés, Perceptual Linear Prediction) (Dave, 2013).

En la Figura 4 se muestra la secuencia de pasos que adoptan las técnicas de aprendizaje automático aplicadas a los sistemas OSS propuestos en el presente trabajo. En esta figura se describen las etapas de pre-procesamiento, entrenamiento y evaluación de los datos que se realizaron para este trabajo. Para la etapa de entrenamiento se procesaron 250 señales tanto para la Clase 1 como para la Clase 2, también fueron utilizadas otras 250 señales distintas para la Clase 1 y 2 para poder realizar la prueba o evaluación del modelo. Estas señales corresponden a las mostradas en la Figura 5 que representan a los coeficientes LPC de cada clase.

Para determinar estos coeficientes LPC, se detalla brevemente a continuación como fue llevado a cabo el cálculo de estos coeficientes.

En primer lugar se calcula la transformada rápida de Fourier FFT (en inglés, Fast Fourier Transform) de la señal X_{norm} con 512 puntos mediante (1).

$$X_k = \sum_{n=1}^N x_n e^{-j2\pi(k-1)(n-1)/N} \tag{1}$$

Luego una vez obtenido $X(k)$ se extrae el módulo y se eleva al cuadrado todos los términos y posteriormente se calcula la transformada inversa discreta de Fourier de este vector con (2).

$$x_n = \frac{1}{N} \sum_{k=1}^N X_k \cdot e^{j2\pi(k-1)(n-1)/N}, \quad 1 \leq n \leq N \tag{2}$$

Así, a partir de (2) obtenemos el valor R el cual será dividido cada elemento de $R = R/m$, donde m representa al número de renglones de la señal original y R corresponde al vector de correlación.

Finalmente para obtener los coeficientes a partir de R se aplica el algoritmo de recursión de Levinson-Durbin para resolver mediante (3).

$$\begin{bmatrix} R(1) & R(2)^* & \dots & R(n)^* \\ R(2) & R(1) & \dots & R(n-1)^* \\ \vdots & \ddots & \ddots & \vdots \\ R(n) & \dots & R(2) & R(1) \end{bmatrix} \begin{bmatrix} A(2) \\ A(3) \\ \vdots \\ A(n+1) \end{bmatrix} = \begin{bmatrix} -R(2) \\ -R(3) \\ \vdots \\ -R(n+1) \end{bmatrix} \tag{3}$$

Donde $R(i)^*$ corresponde al complejo conjugado de $R(i)$.

El otro extractor de características utilizado fueron los Cuantiles. Estos vectores característicos se pueden definir de la siguiente manera: Dado X que representa a una variable aleatoria continua con distribución F esta puede representarse mediante (4) :

$$F(x) = P(X \leq x) \tag{4}$$

En el caso de los cuantiles estos son 3 valores de la variable que dividen equitativamente la distribución en 4 partes iguales. Para el cálculo de los cuantiles se emplea (5).

$$Q_k = \frac{kN}{4} \tag{5}$$

Donde N representa el número de frecuencias absolutas para $k = 1, 2, 3$.

3. Esquema experimental llevado a cabo a partir de las señales del OSS

En la Figura 4, se muestra brevemente como son entrenados los modelos a partir de la base de datos (BD), creada para el presente trabajo. En primer lugar fueron utilizadas 4 particiones de datos, los cuales corresponden a 250 señales por cada partición. La primeras 2 particiones del conjunto de datos corresponden a las señales de entrenamiento para la Clase 1 y Clase 2, así en total fueron empleadas 1000 señales para realizar los experimentos.

Para crear los modelos de entrenamiento tanto para la Clase 1 y la Clase 2 fueron utilizadas 500 señales en total. En el caso de los modelos de evaluación fueron utilizadas las 500 señales restantes. Cabe señalar que estas las señales de entrenamiento y prueba son distintas. En este mismo diagrama se ilustra la parte de extracción de características, la cual es importante señalar dado que fueron empleados dos tipos de extractores de características para el entrenamiento de los modelos. Aunque existe muchas técnicas que permiten la normalización de datos para transformar las variables y seguir conservando las características originales de los datos. En (Jayalakshmi and Santhakumaran, 2011) se puede revisar otro tipo de técnicas que están basadas en el análisis de estadísticos como la media, mediana y la desviación estándar así como también la función sigmoide. En la Figura 6 se muestra el espacio de características de los Cuantiles los cuales fueron calculados para las 4 particiones de datos.

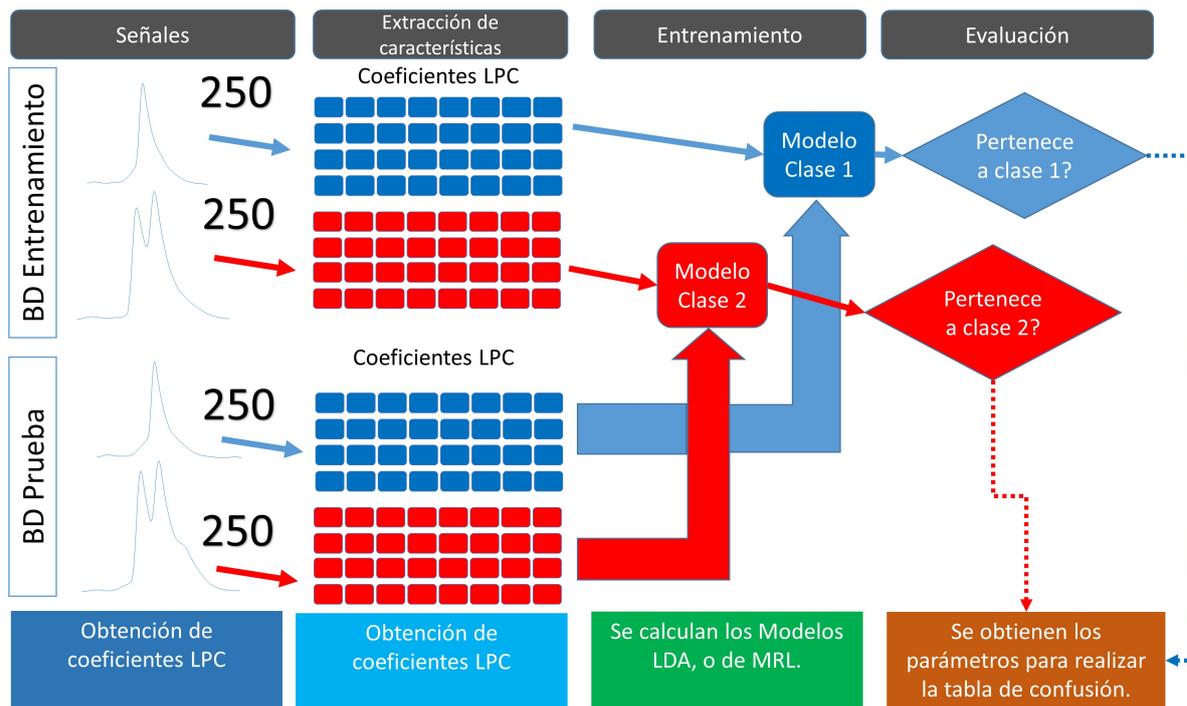


Figura 4: Espacio de características para el conjunto de datos de entrenamiento para las señales pertenecientes a la clase 1 y clase 2. Para este gráfico fueron empleados los coeficientes LPC como extractor de características

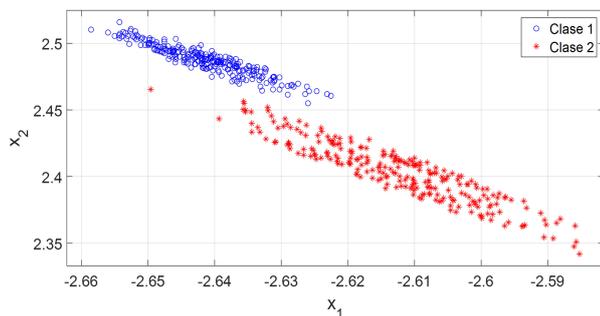


Figura 5: Espacio de características para el conjunto de datos de entrenamiento para las señales pertenecientes a la clase 1 y clase 2. Para este gráfico fueron empleados los coeficientes LPC como extractor de características.

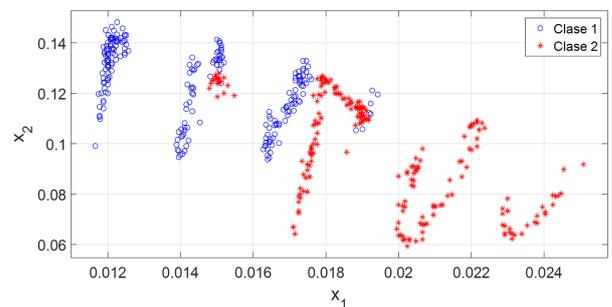


Figura 6: Espacio de características para el conjunto de datos de entrenamiento para las señales pertenecientes a la clase 1 y clase 2. En el caso que se ilustra en este gráfico, fueron utilizados los Cuantiles para caracterizar a las señales del conjunto de prueba

En algunos casos la tasa de reconocimiento de los clasificadores puede mejorar al seleccionar una de estas técnicas que se acaban de mencionar.

Previo a la extracción de características fue empleado una etapa de pre-procesamiento para las 4 particiones de datos donde se realiza una etapa de normalización de los datos mediante máximos y mínimos de la señal correspondiente, véase (6).

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{6}$$

4. Modelo de Regresión Lineal (LR)

La regresión lineal es una de las técnicas más utilizada dentro de la estadística. Con esta herramienta se puede modelar la relación entre dos variables y el resultado de esto es una ecuación lineal de regresión que sirve para realizar predicciones sobre un conjunto de datos.

En este trabajo se pretende realizar un análisis de regresión lineal para encontrar las ecuaciones que modelen dos tipos de patrones que corresponden a los patrones que se generan dentro del sistema OSS. Las características a utilizar para calcular los modelos que mejor se ajustan a (7), corresponden a los coeficientes LPC1 y LPC2 de la señal Xnorm.

$$Y = a + bX \tag{7}$$

Para el cálculo de los coeficientes a y b se utilizan (8) y (9) que se muestran a continuación.

$$a = \frac{\sum y \sum x^2 - \sum x \sum xy}{n \sum x^2 - (\sum x)^2} \quad (8)$$

$$b = \frac{n \sum xy - \sum x \sum y}{n \sum x^2 - (\sum x)^2} \quad (9)$$

Para la visualización del espacio de características de cada conjunto de datos, en las siguientes figuras 7 y 8 se pueden observar los modelos MRL-LPC que anteriormente fueron descritos brevemente.

En la Figura 7 se muestran los dos modelos LR-LPC para la Clase 1 y Clase 2 cuyo coeficiente de regresión calculado para la Clase 1 corresponde a 0.8671. El coeficiente de regresión obtenido para este modelo que pertenece a la clase 2 fue de 0.8597.

En la Figura 8, se muestran los Modelos LR-Cuantiles para la Clase 1 y la Clase 2. Para la Clase 1, el coeficiente de regresión calculado es de 0.2117 y de 0.3542 para la Clase 2.

5. Análisis lineal discriminante (LDA)

La herramienta estadística LDA se puede definir como una función discriminante que relaciona y describe los rasgos y características diferenciales entre poblaciones dos poblaciones. Si se conocen ciertas poblaciones $\Omega_1, \dots, \Omega_g$ y de cada una de ellas se observa una muestra de $X = (X_1, \dots, X_p)'$.

El análisis discriminante lineal se basa principalmente en buscar funciones discriminantes o reglas de decisión $h = h(X_1, \dots, X_p)'$ en los cuales estos valores en los distintos grupos estén lo más separados posible. En otras palabras LDA tiene la finalidad de encontrar las funciones h permitan asignar cada observación $x = (x_1, \dots, x_p)'$ a cierta población Ω_i y que se minimice la tasa de error en dicha asignación.

Es importante mencionar que las funciones discriminantes son construidas a partir de la muestra, dado que esto representa uno de los problemas de clasificación el cual consiste en que la clasificación de una nueva observación x , cuya población de procedencia es desconocida. Un ejemplo de un discriminador lineal se puede construir a partir de dos poblaciones Ω_1 y Ω_2 con distribuciones $N_p(\mu_1, \Sigma)$ y $N_p(\mu_2, \Sigma)$, este discriminador asigna $x \in \mathbb{R}^p$ a una de las poblaciones que se mencionaron anteriormente. A este discriminador se le conoce como discriminador lineal de Fisher y este se representa por (10).

$$L(x) = (x - \mu_1 + \mu_2)^T \Sigma^{-1} (\mu_1 - \mu_2) \quad (10)$$

Esta regla discriminante etiqueta x a la población Ω_1 si $L(x) > 0$ y en el caso contrario x es asignado a la población Ω_2 . El entrenamiento de los modelos LDA realizado en el presente trabajo puede apreciarse en las siguientes figuras 8 y 9. Los cuales representan a los modelos LDA-LPC y LDA-Cuantiles respectivamente. Posteriormente en la sección de resultados serán mostrados la tasa de reconocimiento de estos modelos LDA así como también de los modelos LR.

6. Resultados

Esta sección está enfocada en mostrar los resultados de los modelos LDA-(LPC/Cuantiles), LR-(LPC/Cuantiles). El orden de los resultados que se mostraran, serán de la siguiente forma: en primer lugar se mostraran los resultados de LPC-LPC (en Tabla 1), en segundo lugar se mostraran los modelos LR-LPC (en Tabla 2), posteriormente seguirían los resultados de los modelos entrenados con LDA-Cuantiles (en Tabla 3), y finalmente LR-Cuantiles (en Tabla 4).

En la Tabla 1 se muestran los resultados que corresponde al modelo LDA-LPC aplicado a la señal óptica. Aquí se puede apreciar que de las 250 señales de la Clase 1 que fueron utilizadas para probar el modelo LDA de esta clase, fueron etiquetadas 249 señales como Clase 1 y solo 1 señal fue catalogada erróneamente como Clase 2. A las 249 señales se les conocen como verdaderos positivos y la señal restante es conocida como un falso positivo ya que fue etiquetada erróneamente como Clase 2.

Tabla 1: Resultados obtenidos de los experimentos para la clasificación de los modelos LDA-LPC para la Clase 1 y la Clase 2

		Clase Predicha	
		Positivo	Negativo
Actual	Positivo	249	1
	Negativo	0	250

Los resultados que se muestran en esta misma tabla para la Clase 2 también se evaluaron con 250 señales de prueba y estas señales fueron independientes a las utilizadas para el entrenamiento del modelo. Cabe mencionar que de las 250 señales, todas fueron clasificadas correctamente, es decir que el sistema pudo distinguir al 100 % a que clase correspondía la señal de prueba. En términos de sensibilidad el sistema tiene un 100 %, esto quiere decir que tiene la capacidad en ese porcentaje de distinguir correctamente la Clase 1 como la Clase 1, esto fue a partir del cálculo en base al conjunto de señales de prueba. A partir de los resultados obtenidos el sistema tiene un 99.6 % en términos de especificidad que significa que es capaz de reconocer el 99.6 % de las señales de prueba de la Clase 2 como la Clase 2.

En la Tabla 2 se ilustra los resultados aplicando el modelo de regresión lineal para clasificar las señales de prueba tanto para la Clase 1 como de la Clase 2. Los modelos LR-LPC fueron calculados a partir de los coeficientes LPC1 y LPC2, esto fue de la misma forma en que se realizó con los modelos LDA para las dos clases (Clase 1 y Clase 2). De las 250 señales de prueba empleadas para la Clase 1, el modelo LR-LPC las clasificó como Clase 1. Esto significa que se registraron 250 verdaderos positivos.

Por otro lado, las restantes 250 señales de prueba de la Clase 2 fueron etiquetadas 250 pertenecientes a la Clase 2. Estas señales corresponden a verdaderos negativos. En este modelo no existieron errores en la clasificación. Esto quiere decir que el sistema tiene una exactitud del 100 % para poder distinguir la Clase 1 de la Clase 2. En términos de sensibilidad y especi-

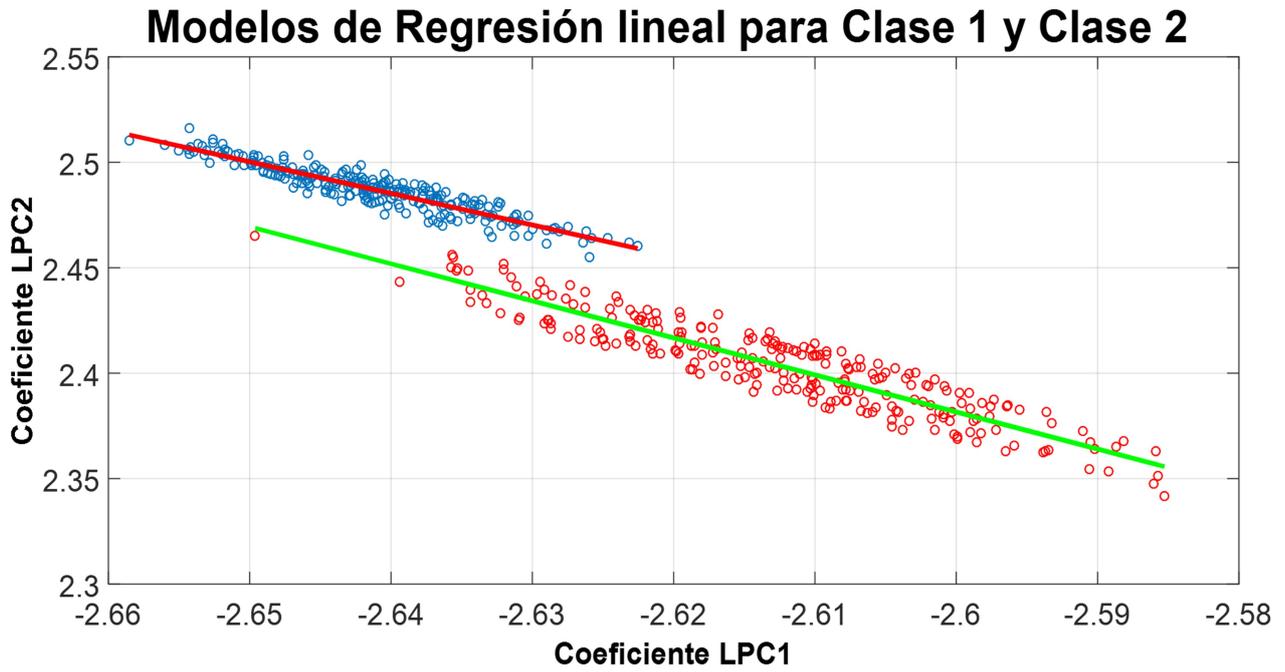


Figura 7: Modelo de regresión lineal para la Clase 1 y Clase 2 utilizando coeficientes LPC1 y LPC2

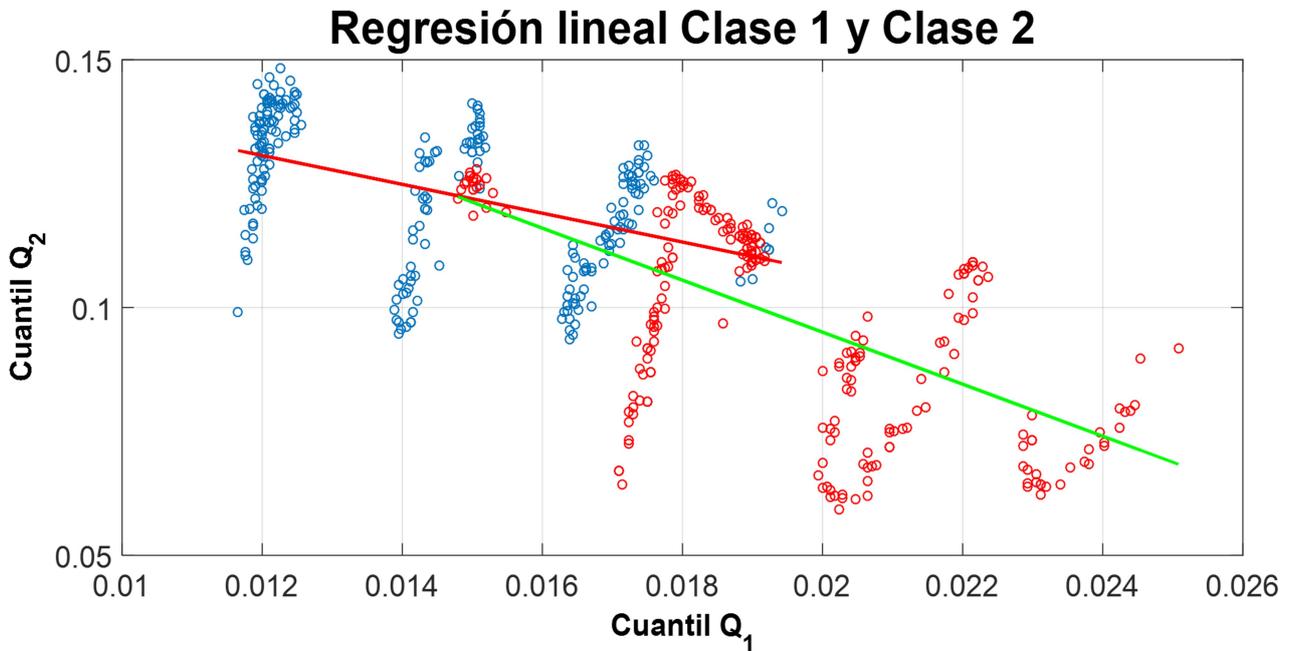


Figura 8: Modelo de regresión lineal para la Clase 1 y Clase 2 utilizando Cuantiles Q_1 y Q_2

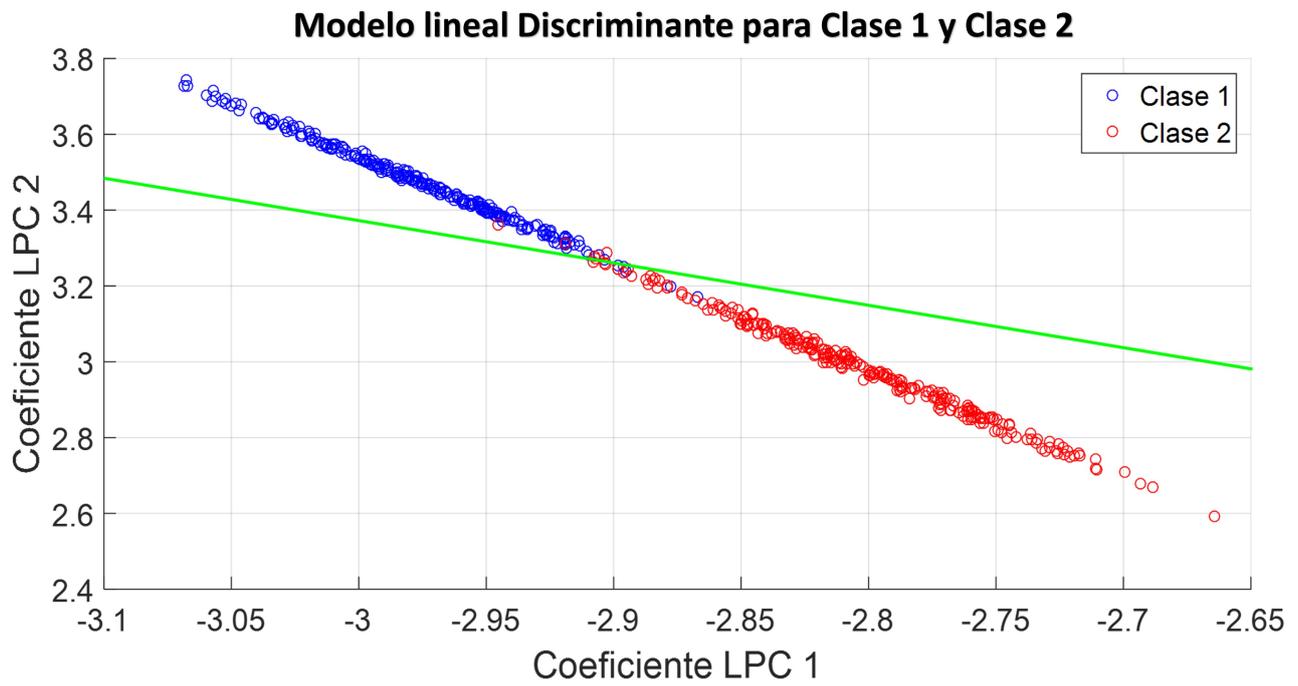


Figura 9: Modelo Lineal Discriminante para la Clase 1 y Clase 2 aplicando LPC como extractor de características

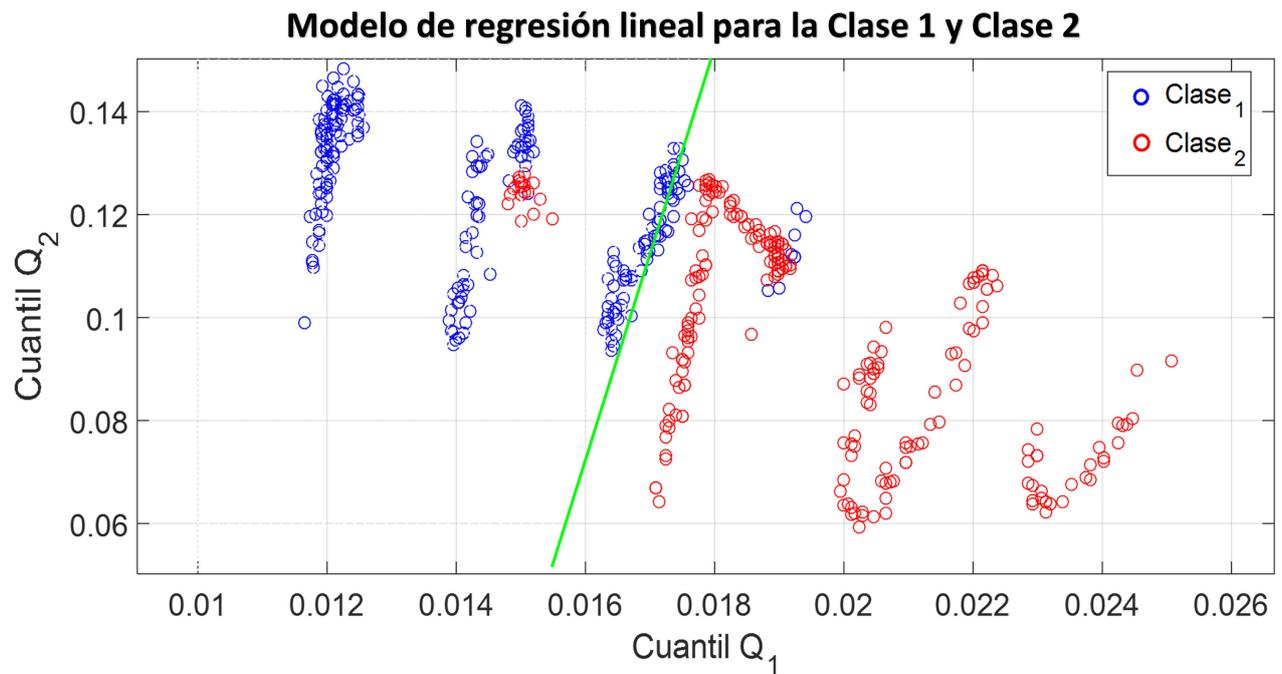


Figura 10: Modelo de regresión lineal para la Clase 1 y Clase 2 aplicando Cuantiles como extractor de características

ficidad el sistema de igual manera tiene un 100 % dado que la tasa de error de reconocimiento es de 0.

Tabla 2: Resultados obtenidos de los experimentos para la clasificación de los modelos LR-LPC para la Clase 1 y la Clase 2

		Clase Predicha	
		Positivo	Negativo
Actual	Positivo	250	0
	Negativo	0	250

En la siguiente Tabla 3 se ilustra los resultados de los experimentos realizados con LDA-Cuantiles como clasificador para las señales de las clases 1 y 2. El sistema de clasificación pudo reconocer 227 señales de 250 que pertenecían a la Clase 1, y el resto de las señales el sistema las clasificó como pertenecientes a la Clase 2. Para el reconocimiento con la Clase 2, el sistema clasificó correctamente 229 señales como señales pertenecientes a la Clase 2, y 21 señales fueron etiquetadas incorrectamente como Clase 1.

A partir de los parámetros anteriores fueron calculados los siguientes indicadores del modelo LDA en términos de porcentaje como: sensibilidad, precisión y exactitud con 91.53 %, 90.87 % y 91.2 % respectivamente.

Tabla 3: Resultados obtenidos de los experimentos para la clasificación de los modelos LDA-Cuantiles para la Clase 1 y la Clase 2

		Clase Predicha	
		Positivo	Negativo
Actual	Positivo	227	23
	Negativo	21	229

Los resultados de la Tabla 4 fueron obtenidos a partir del modelo LR-Cuantiles. El procedimiento para evaluar estos modelos fue el siguiente: en primer lugar se utilizaron 250 señales de prueba de la Clase 1 para evaluar el modelo LR-Cuantiles de la Clase 1, después el sistema clasificó correctamente 172 señales y 78 señales fueron etiquetadas incorrectamente como Clase 2. Para evaluar el modelo LR-Cuantiles para la Clase 2 fueron utilizadas 250 señales de prueba de la Clase 2.

A partir del conjunto de datos de prueba de la Clase 2 el sistema clasificó correctamente 122 y el resto de las 128 señales fueron etiquetadas incorrectamente como Clase 1 cuando originalmente pertenecían a la Clase 2. Finalmente con estos parámetros fueron estimados los indicadores del rendimiento del clasificador LR-Cuantiles como: sensibilidad, precisión y exactitud con 57.34 %, 61 % y 58.5 % respectivamente.

Tabla 4: Resultados obtenidos de los experimentos para la clasificación de los modelos LR-Cuantiles para la Clase 1 y la Clase 2

		Clase Predicha	
		Positivo	Negativo
Actual	Positivo	172	78
	Negativo	128	122

7. Conclusiones

En el presente documento, se han presentado 2 metodologías para el reconocimiento de patrones que se generan en el contexto de sistemas OSS. También, para manejar de una manera conveniente los conjuntos de datos para las Clases 1 y 2 fueron utilizados dos tipos de técnicas para la extracción de características, los cuales fueron los LPC's y Cuantiles.

La propuesta de LDA y LPC correspondiente a la Tabla 1 registró una exactitud de 99.8 % y el LR-LPC alcanzó un 100 % de acuerdo a Tabla 2, todo esto fue calculado a partir de la evaluación con señales distintas a las que se utilizaron para el entrenamiento.

La Tabla 3 y Tabla 4 fueron para mostrar la tasa de reconocimiento de los modelos LDA-Cuantiles y LR-Cuantiles respectivamente. La exactitud de estas configuraciones aplicando estos dos modelos con estos vectores de características son los siguientes: para LDA un 91.2 % y con LR se calculó un 58.8 %. De acuerdo a los resultados obtenidos en estas tablas, los modelos de LR-LPC son los que se ajustan mejor a los datos en comparación con los resultados obtenidos con los modelos LDA-LPC. Así mismo de acuerdo a la Figura 5 y Figura 6, los atributos generados con LPC se ajustan mejor que los Cuantiles. Esto se refleja en que, para tareas de reconocimiento los coeficientes LPC y modelos LR o LDA son herramientas convenientes para ser utilizados en sistemas OSS.

Trabajos futuros

El desarrollo de sistemas de barrido ópticos para tareas de monitoreo de salud estructural conlleva a la implementación de técnicas que permitan la resolución de problemas en tiempo real. Es indispensable emplear dispositivos que procesen imágenes y señales para el reconocimiento de patrones. El uso de lenguajes de programación como Python permitiría determinar los coeficientes LPC y calcular los modelos en tiempo real y así gestionar los recursos de una tarjeta como FPGA (en inglés, Field-programmable gate array), PSoC (en inglés, Programmable System on Chip) o Raspberry.

Agradecimientos

Este trabajo ha sido realizado parcialmente gracias al apoyo de Conacyt y al Instituto de Ingeniería de la Universidad Autónoma de Baja California.

Referencias

- Brooks, D. R., Mims III, F. M., 2001. Development of an inexpensive handheld led-based sun photometer for the globe program. *Journal of Geophysical Research: Atmospheres* 106 (D5), 4733–4740.
DOI: 10.1029/2000JD900545
- Cervantes, J., Taltempa, J., Lamont, F. G., Castilla, J. S. R., Rendon, A. Y., Jali, L. D., 2017. Análisis comparativo de las técnicas utilizadas en un sistema de reconocimiento de hojas de planta. *Revista Iberoamericana de Automática e Informática industrial* 14 (1), 104–114.
DOI: 10.1016/j.riai.2016.09.005
- Cheng, P., John, W., Zheng, W., 2002. Large structure health dynamic monitoring using gps technology. In: FIG XXII International Congress, Washington, DC USA. pp. 1–10.
- Dave, N., 2013. Feature extraction methods lpc, plp and mfcc in speech recognition. *International journal for advance research in engineering and technology* 1 (6), 1–4.
- Di Sante, R., 2015. Fibre optic sensors for structural health monitoring of aircraft composite structures: Recent advances and applications. *Sensors* 15 (8), 18666–18713.
URL: <https://www.mdpi.com/1424-8220/15/8/18666>
DOI: 10.3390/s150818666
- Doebbling, S., Farrar, C., Prime, M., Shevitz, D., 5 1996. Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: A literature review. Report.
DOI: 10.2172/249299
- Feng, D., Feng, M. Q., 2017. Experimental validation of cost-effective vision-based structural health monitoring. *Mechanical Systems and Signal Processing* 88, 199–211.
DOI: <https://doi.org/10.1016/j.ymsp.2016.11.021>
- Flores-Fuentes, W., López, M., Sergiyenko, O., González-Navarro, F. F., Rivera-Castillo, J., Hernandez-Balbuena, D., Rodríguez-Quiñonez, J., 2014. Combined application of power spectrum centroid and support vector machines for measurement improvement in optical scanning systems. *Signal Processing* 98, 37–51.
DOI: 10.1016/j.sigpro.2013.11.008
- Flores-Fuentes, W., Miranda-Vega, J. E., Rivas-López, M., Sergiyenko, O., Rodríguez-Quiñonez, J. C., Lindner, L., 2018. Comparison between different types of sensors used in the real operational environment based on optical scanning system. *Sensors* 18 (6).
DOI: 10.3390/s18061684
- Jayalakshmi, T., Santhakumaran, A., 2011. Statistical normalization and back propagation for classification. *International Journal of Computer Theory and Engineering* 3 (1), 1793–8201.
- Jo, H., Sim, S.-H., Tatkowski, A., Spencer Jr, B., Nelson, M. E., 2013. Feasibility of displacement monitoring using low-cost gps receivers. *Structural Control and Health Monitoring* 20 (9), 1240–1254.
- Jung, H. K., Park, G., 2018. Integrating passive-and active-sensing techniques using an l-shaped sensor array for impact and damage localization. *Journal of Intelligent Material Systems and Structures* 29 (17), 3436–3443.
- Lindner, L., Sergiyenko, O., Rodríguez-Quiñonez, J. C., Rivas-Lopez, M., Hernandez-Balbuena, D., Flores-Fuentes, W., Murrieta-Rico, F. N., Tyrsa, V., 2016. Mobile robot vision system using continuous laser scanning for industrial application. *Industrial Robot: An International Journal*.
- Mims, F. M., Dec 2000. Solar radiometer with light-emitting diodes as spectrally-selective detectors. *Appl. Opt.* 39 (34), 6517–6518.
URL: <http://ao.osa.org/abstract.cfm?URI=ao-39-34-6517>
DOI: 10.1364/AO.39.006517
- Miranda-Vega, J. E., Rivas-Lopez, M., Flores-Fuentes, W., Sergiyenko, O., Lindner, L., Rodríguez-Quiñonez, J. C., 2019. Implementación digital de filtros fir para la minimización del ruido óptico y optoelectrónico de un sistema de barrido óptico. *Revista Iberoamericana de Automática e Informática industrial* 16, 344–357.
DOI: 10.4995/riai.2019.10210
- Rivera-Castillo, J., Flores-Fuentes, W., Rivas-Lopez, M., Sergiyenko, O., Gonzalez-Navarro, F. F., Rodríguez-Quiñonez, J. C., Hernandez-Balbuena, D., Lindner, L., Bãşaca-Preciado, L. C., 2017. Experimental image and range scanner datasets fusion in shm for displacement detection. *Structural Control and Health Monitoring* 24 (10), e1967.
DOI: 10.1002/stc.1967
- Sergiyenko, O., Hernandez, W., Tyrsa, V., Cruz, L. F. D., Starostenko, O., Peña-Cabrera, M., 2009. Remote sensor for spatial measurements by using optical scanning. *Sensors* 9 (7), 5477–5492.
- Van der Auweraer, H., Peeters, B., 2003. Sensors and systems for structural health monitoring. *Journal of Structural Control* 10(2), 117–125.
DOI: :10.1002/stc.21
- X.Ba, Q.Pan, B.Ju, Z.Feng, 2017. Ultrafast displacement actuation of piezoelectric stacks with time-sequence. *IEEE Transactions on Industrial Electronics* 64, 2955–2961.
DOI: 10.1109/TIE.2016.2631119