

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

FACULTAD DE CIENCIAS E INGENIERÍA



**PONTIFICIA
UNIVERSIDAD
CATÓLICA
DEL PERÚ**

**EXPLORACIÓN DE TÉCNICAS AUTOMÁTICAS DE
DETECCIÓN DE LÍNEAS-B EN IMÁGENES DE ULTRASONIDO
PARA DIAGNÓSTICO DE NEUMONÍA EN PACIENTES
PEDIÁTRICOS**

Tesis para optar el Título de Ingeniero Electrónico, que presenta el bachiller:

Grecia María Thais Eche Zapata

ASESOR: Dr. Ing. Benjamín Castañeda Aphan

CO-ASESOR: Mág. Ing. Omar Zenteno

Lima, octubre del 2017



A mi hermano Marlon. Por enseñarme las cosas más importantes de la vida.

AGRADECIMIENTOS

A la Dirección General de Investigación de la Pontificia Universidad Católica del Perú, por el financiamiento parcial del proyecto "Exploración de técnicas automáticas de detección de líneas-B en imágenes de ultrasonido para diagnóstico de neumonía en pacientes pediátricos" (DGI 2016-161) y por el financiamiento del proyecto "Detección de neumonía en niños utilizando técnicas ultrasónicas avanzadas" (DGI 073-2014), a través del Programa de Apoyo al Desarrollo de Tesis de Licenciatura (PADET).



RESUMEN

La neumonía es la principal causa de muerte en niños menores de 5 años a nivel mundial. Los métodos radiológicos ionizantes (Rayos X y Tomógrafos computarizados) son considerados los estudios de referencia para su detección. Sin embargo, los pacientes son expuestos a radiación durante la prueba, y el riesgo de daño es mayor en poblaciones pediátricas.

El presente trabajo analiza los histogramas de espacios intercostales extraídos de videos ultrasónicos de pulmón en niños, para su clasificación entre sanos y enfermos, dentro de un video. Para ello, se trabajó con 15 videos de pacientes enfermos y 15 videos de pacientes sanos.

Los espacios intercostales (región de interés) se encuentran debajo de la línea pleural en cada cuadro de video. Para identificar la línea pleural se implementó un algoritmo basado en el análisis del centroide de la imagen, donde se obtuvo las áreas que conforman la zona pleural, y mediante interpolación, los puntos de dicha línea. Estos puntos fueron determinantes para la segmentación de los espacios intercostales, ya que marcaron la referencia de inicio para la segmentación. Finalmente, de dichos espacios segmentados, se extrajeron características numéricas de oblicuidad, curtosis, desviación estándar, energía y promedio.

El potencial de clasificación de las propiedades fue evaluado individualmente, en pares, y en un solo grupo de 5. Para el análisis de una sola característica, el umbral óptimo de clasificación fue seleccionado por Curva ROC (*receiver operator characteristic*); para el estudio de las características en pares, se usó análisis SVM (*support vector machine*) usando kernel RBF; y para el estudio de las 5 características en simultáneo se usó PCA (*principal component analysis*) para hallar las dos componentes principales y aplicar SVM para la clasificación. Los resultados revelaron que el promedio es el mejor discriminador cuando se analizaba una sola característica, con 77% de sensibilidad, 75% de especificidad y 75% de exactitud. Cuando se analizó características en pares, el promedio y oblicuidad permitieron la mejor clasificación con 93% de sensibilidad, 86% de especificidad y 88% de exactitud. Finalmente, analizando las 5 características en simultáneo, los resultados fueron: 100% de sensibilidad, 98% de especificidad y 98% de exactitud.



TEMA DE TESIS PARA OPTAR EL TÍTULO DE INGENIERO ELECTRÓNICO

Título : Exploración de técnicas automáticas de detección de líneas-B en imágenes de ultrasonido para diagnóstico de neumonía en pacientes pediátricos.

Área : Circuitos y Sistemas Electrónicos

Asesor : Benjamín Castañeda

Co-Asesor : Omar Zenteno Valdiviezo

Alumno : Grecia Eche Zapata

Código : 20111129

Fecha : 21/06/2016

1326



Descripción y Objetivos

La neumonía es la principal causa de muerte en niños menores de 5 años a nivel mundial. Tiene como característica la presencia de líquido en los pulmones, lo cual impide una correcta absorción de oxígeno. Los métodos estándar para su detección son Rayos X y Tomografía computarizada, presentando la desventaja del uso de radiación a la cual se expone a los pacientes. Si bien es cierto, el método ultrasónico no utiliza radiación ionizante en la detección, la desventaja que sí presenta es la necesidad de un especialista que provea un diagnóstico.

El objetivo principal de la presente tesis es desarrollar un algoritmo que detecte la presencia de "líneas B" en las imágenes de ultrasonido en base a las características matemáticas de su histograma, y pueda realizar un diagnóstico de la enfermedad.

Las líneas B son artefactos verticales que se visualizan en los videos ultrasónicos de pacientes enfermos de neumonía, esto se produce debido a los ecos enviados por la sonda que irrumpen a través de un medio con presencia de líquido, en este caso, a través de los pulmones.

El desarrollo del algoritmo para la detección se realizará con el software MATLAB 2014a y se trabajará con videos de pacientes ya diagnosticados provenientes del "Instituto Nacional de Salud del Niño".

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ
FACULTAD DE INGENIERÍA

M. Sc. Ing. NIQUEL ANGEL CATARO SANCHEZ
Coordinador de la Especialidad de Ingeniería Electrónica

MÁXIMO 50 PÁGINAS



TEMA DE TESIS PARA OPTAR EL TÍTULO DE INGENIERO ELECTRÓNICO

Título : Exploración de técnicas automáticas de detección de líneas-B en imágenes de ultrasonido para diagnóstico de neumonía en pacientes pediátricos.

Índice

Introducción

1. Capítulo 1: Neumonía. Problemática, objetivos y justificación
2. Capítulo 2: Terminología básica e información sobre el procesamiento de imágenes
3. Capítulo 3: Metodología usada antes y durante la implementación del algoritmo de detección de la enfermedad
4. Capítulo 4: Resultados, análisis y discusión

Conclusiones

Recomendaciones

Bibliografía

Anexos

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ
FACULTAD DE CIENCIAS E INGENIERÍA

M. Sc. Ing. MIGUEL ÁNGEL CATANO SÁNCHEZ
Coordinador de la Especialidad de Ingeniería Electrónica

MÁXIMO 50 PÁGINAS

Contenido

Introducción	1
Capítulo 1: Neumonía. Problemática, objetivos y justificación	2
1.1 Problemática	2
1.2 Neumonía	3
1.3 Métodos de detección de neumonía	3
1.3.1 Radiografía de tórax (rayos X)	3
1.3.2 Tomografía axial computarizada	5
1.3.3 Ultrasonido de tórax	6
1.4 Estado del arte	7
1.5 Objetivos	9
Capítulo 2: Terminología básica e información sobre el procesamiento de imágenes	10
2.1 Sonda ultrasónica	10
2.2 Formación de una imagen de ultrasonido	10
2.2.1 Modo A	11
2.2.2 Modo B	11
2.3 Características del pulmón en la imagen de ultrasonido	11
2.3.1 Líneas A	11
2.3.2 Líneas B	12
2.3.3 Deslizamiento pulmonar y pulso pulmonar	13
2.4 Procesamiento de la imagen digital	13
2.4.1 Preparación de la muestra	13
2.4.2 Extracción de características del histograma	13
2.4.3 Definición de herramientas en el desarrollo del algoritmo	16
2.4.3.1 Matriz binaria	16
2.4.3.2 Interpolación con spline cúbico	16
2.4.3.3 Umbralización	17
2.4.3.4 Centroide o centro de masa	17
2.4.3.5 Operación morfológica de apertura	17
2.4.3.6 Máquina de vector de soporte	18
2.4.3.7 Análisis de componentes principales	22
2.5 Análisis de resultados	23

2.5.1	Análisis de datos	23
2.5.2	Análisis de resultados	23
2.5.2.1	Sensibilidad	24
2.5.2.2	Especificidad	24
2.5.2.3	Exactitud	24
2.5.2.4	Curvas ROC	24
Capítulo 3:	Metodología usada antes y durante la implementación del algoritmo de detección de la enfermedad	26
3.1	Adquisición de la base de datos en pacientes y consideraciones necesarias para dicha adquisición	26
3.2	Secuencia del procedimiento usado en el algoritmo	27
3.2.1	Pre-procesamiento de la base de datos	28
3.2.2	Detección automática de la línea pleural	28
3.2.3	Detección automática de los espacios intercostales	35
3.2.4	Análisis de los espacios intercostales	37
3.3	Extracción de las características de los histogramas de cada espacio intercostal	37
3.3.1	Conjunto de entrenamiento del algoritmo	37
3.3.2	Valores cuantitativos de espacios intercostales sanos y enfermos	38
3.3.3	Métodos para el análisis de los vectores de datos	40
3.3.3.1	Análisis con Curva ROC	40
3.3.3.2	Aprendizaje automático: Análisis con máquina de vector de soporte (<i>Support vector machine</i>)	41
3.3.3.3	Aprendizaje automático: Análisis de componentes principales con máquina de vector de soporte	42
3.4	Diagrama de bloques del algoritmo	43
Capítulo 4:	Resultados, análisis y discusión	44
4.1	Resultados de la segmentación de pleura	44
4.2	Resultados del Análisis por Curva ROC	45
4.3	Resultados con el uso de máquina de vector de soporte	47

4.4 Resultados con el uso de Análisis de componentes principales y máquina de vector de soporte	49
4.5 Discusión de los resultados obtenidos	55
4.5.1 Primer método de análisis (Curva ROC)	55
4.5.2 Segundo método de análisis (máquina de vector de soporte)	55
4.5.3 Tercer método de análisis (máquina de vector de soporte y PCA)	56
Conclusiones	57
Recomendaciones y consideraciones finales.....	58
Bibliografía	59



Introducción

La neumonía es una enfermedad inflamatoria del sistema respiratorio que afecta normalmente a los espacios alveolares de los pulmones. Cuando los alveolos son infectados, se llenan de líquido y pus ocasionando dolor en el paciente [1].

Según la OMS (Organización Mundial de la Salud), es la principal causa de muerte infantil, causando el 15% de mortandad a nivel internacional y el 11.5% a nivel nacional [1,2].

Los métodos más usados para su diagnóstico son los rayos X y tomografía computarizada. Sin embargo, la principal desventaja inherente a estos métodos es la radiación ionizante, la cual puede ser perjudicial para la salud a nivel celular, sobre todo para los niños en crecimiento. En contraste, la ultrasonografía como método de detección no utiliza radiación, pero la calidad reducida de las imágenes y la necesidad de un radiólogo que pueda proveer un diagnóstico apropiado, limitan las aplicaciones prácticas de la técnica. La principal anomalía causada por neumonía, que se presenta en las imágenes de ultrasonido, son las líneas B, que aparecen como artefactos verticales. Este efecto es debido a los ecos enviados por la sonda del ecógrafo que irrumpen a través de un medio con presencia de líquido, en este caso, a través de los pulmones.

El objetivo de la presente tesis es desarrollar un algoritmo que detecte la presencia de "líneas B" en las imágenes de ultrasonido (obtenidas de videos de pacientes con padecimiento de neumonía) y estimar la sensibilidad, especificidad y exactitud de dicha detección, por video.

El presente trabajo está formado por cuatro capítulos. En el primer capítulo se describen el contexto del problema, el estado del arte y los objetivos de la tesis. El segundo capítulo describe la teoría y el formalismo matemático necesario para el desarrollo del algoritmo. El tercer capítulo describe la metodología empleada para la adquisición de la base de datos de videos ecográficos, el diagrama de bloques del proyecto y la metodología de implementación de los algoritmos. Finalmente, en el cuarto y último capítulo, se presentan y discuten los resultados finales de los algoritmos en el conjunto de prueba y entrenamiento, indicando la sensibilidad, especificidad y exactitud de los clasificadores implementados.

CAPÍTULO 1: Neumonía. Problemática, objetivos y justificación.

En el presente capítulo se explica la problemática de neumonía en el Perú y el mundo, su definición, métodos de detección, los objetivos y la motivación para la presente tesis.

1.1 Problemática

La neumonía es una enfermedad infecciosa respiratoria cuya tasa de mortandad es de 15% en niños menores de 5 años a nivel mundial y en Perú, del 11.5%. [1,2] Ver **Figura 1.1**.

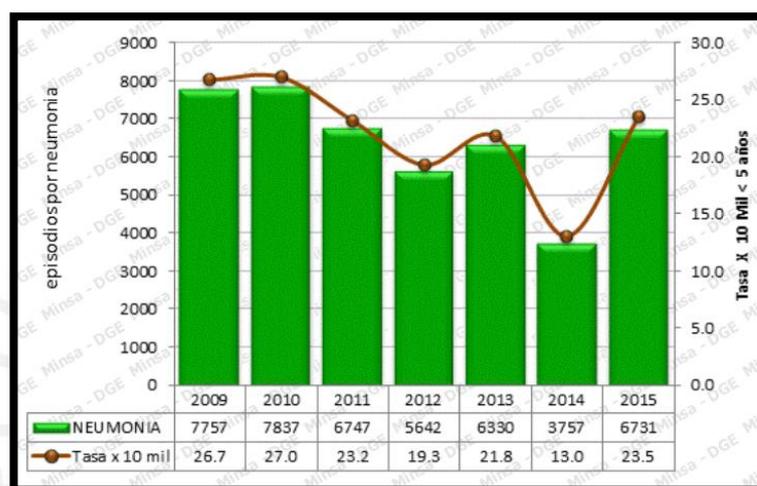


Figura 1.1. Estadísticas de casos de neumonía en menores de 5 años, del 2009 al 2015 en Perú. Extraído de [3].

Si se detecta a tiempo, la enfermedad puede curarse. Sin embargo, en los países menos desarrollados, la adquisición de los tomógrafos, considerados como estudios referencia para su detección, está limitada debido al alto costo que conlleva adquirirlos [54]. A eso se suma la necesidad de un experto en salud que pueda interpretar los resultados y dar un diagnóstico. La otra desventaja es el uso de radiación ionizante (rayos X y Tomografías) por un periodo prudente en el paciente [54], lo cual conllevará a problemas futuros sobre todo si se trata de niños menores de 5 años.

Si bien es cierto, el método ultrasónico presenta la ventaja de no usar radiación ionizante, lo cual no implicará daños futuros para el paciente, la desventaja que sí presenta es la necesidad de especialistas que provean el diagnóstico final. Lamentablemente, no en todas las zonas rurales de países se puede gozar de este beneficio. Por ello, radica la importancia de desarrollar un algoritmo que pueda brindar un diagnóstico temprano sobre si

se padece o no de neumonía y poder empezar un tratamiento en el paciente lo antes posible. De esta manera, el radiólogo podría ejecutar un algoritmo de detección y dar el diagnóstico al paciente a partir del resultado cuantitativo obtenido.

Las ventajas del desarrollo de un algoritmo como este son, por lo tanto, la reducción del tiempo de entrenamiento del radiólogo, la portabilidad de usarlo en zonas en casos de emergencia [54], y la reducción del error que puede surgir al hacer un diagnóstico especializado. Esto último debido a que el análisis que se hace por parte de un erudito en el campo, es visual y subjetiva, y en el caso del presente trabajo, será cuantitativa.

1.2 Neumonía

La neumonía es una forma de infección respiratoria aguda que afecta a los pulmones. Los pulmones se componen de pequeños sacos llamados alvéolos, que se llenan de aire cuando una persona sana respira. Cuando una persona tiene neumonía, los alvéolos se llenan de pus y líquido, lo que hace que la respiración sea dolorosa y limite la cantidad de oxígeno que llega a los pulmones. Es causada por virus, bacterias u hongos [2].

Según la OMS, la neumonía fue causa de muerte de un estimado de 922 000 niños menores de 5 años en 2015. Esta enfermedad afecta sobre todo, a nivel mundial, a la población pediátrica de zonas localizadas en el sur de Asia y África sub-sahariana [2], y a nivel nacional, a las zonas más pobres de las regiones andina y amazónica. Esto refleja la inequidad social [1].

La neumonía puede ser prevenida si se detecta a tiempo, con tratamientos médicos y medicina de bajo costo [2]. Es por ello que la detección temprana es de vital importancia para evitar la mortandad infantil a causa de esta enfermedad.

1.3 Métodos de detección de neumonía

Algunos de los métodos usados para la detección de neumonía mediante imágenes médicas son: [4]

1.3.1 Radiografía de tórax (rayos X)

Es la modalidad fundamental del diagnóstico de neumonía [4]. En el procedimiento de obtención de imágenes, se utiliza radiación

electromagnética, la cual se forma en una máquina de rayos-X cuando un haz de electrones que es enviado a gran velocidad, bombardea un ánodo de tungsteno. Ver **Figura 1.2**.

Esta radiación tiene una longitud de onda mucho menor que la luz visible, permitiendo que pueda atravesar el medio. En este caso, el cuerpo humano [8].

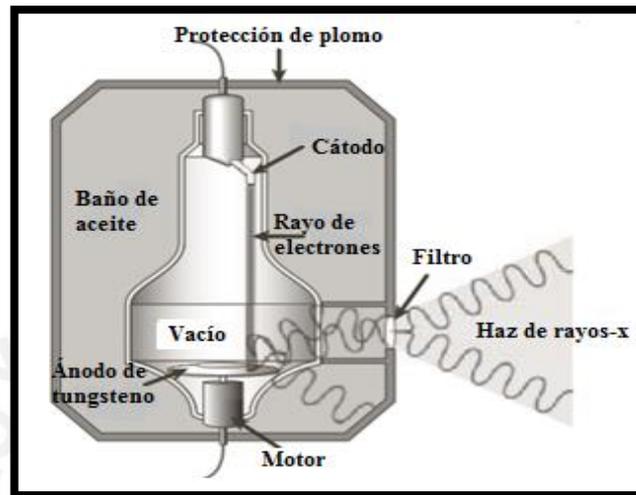


Figura. 1.2. Máquina de rayos-X. Adaptado de [8].

Las imágenes de rayos X se producen gracias a las diferentes densidades de los tejidos del cuerpo, lo cual permitirá ver dentro de él gracias a la creación de un “diagrama de sombras”[8].

Cuando una persona tiene neumonía, implica que tiene líquido almacenado en los pulmones y por tanto, esa parte se verá de color gris, tal como se muestra en la **Figura 1.3**.

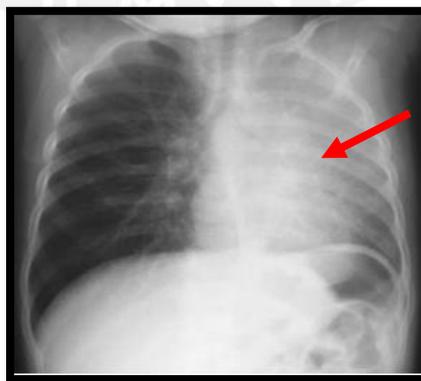


Figura 1.3. Radiografía de un niño de 5 años con presencia de neumonía en el pulmón izquierdo (señalado con una flecha roja). Extraído de [4].

Los rayos-X desprenden electrones de la superficie de un átomo. Esto genera la producción de iones, los cuales son moléculas inestables que

buscan estabilizarse donando el electrón extra que tienen a otras moléculas en las células del cuerpo. Este proceso afecta sobre todo a las proteínas, ADN y otras moléculas vitales para el organismo. Los cambios producidos a nivel celular en óvulos o espermatozoides pueden afectar a los cromosomas tanto en su estructura como en ciertos genes llegando a causar mutaciones que pueden provocar defectos al nacimiento, partos de fetos muertos o abortos [41]. Entre las enfermedades causadas debido a esta radiación, se encuentran el cáncer, dolor y enrojecimiento de la piel, o traer consigo problemas digestivos, anemia, náuseas, fatiga, muerte de células sanguíneas, caída del cabello o esterilidad [42].

Teniendo en cuenta todo esto, el cuerpo en crecimiento de los niños implica una división más rápida de sus células, ocasionando que sean más vulnerables a esta radiación [8].

1.3.2 Tomografía Axial Computarizada

Es el segundo de los estudios de referencia para la detección de neumonía debido a la calidad de su imagen, pero su uso es limitado debido a la exposición a radiación y su alto costo [5]. El acceso a un tomógrafo computarizado es escaso, y a nivel público, el paciente puede esperar hasta tres meses por estudios de imágenes. Entonces los servicios colapsan por la demanda de pacientes que se reciben diariamente [43].

La tomografía axial computarizada, como método de análisis, permite obtener imágenes transversales del cuerpo, de esta manera observamos imágenes en dos dimensiones que representan el volumen de los tejidos [8].

Las imágenes de TC (tomografía computarizada) se obtienen a través de la emisión y recepción de rayos X. De manera similar al método radiográfico, una fuente emite rayos X que atraviesan el cuerpo y son captados por un detector. Ver **Figura 1.4**.

En el caso de TC, la fuente emisora de rayos X y los detectores van girando alrededor del paciente, de manera que los detectores van captando imágenes del cuerpo desde diferentes ángulos. Toda esa información es procesada por una computadora y es plasmada en una imagen de ese sector del cuerpo o “rodaja” (comúnmente conocido) que se aprecia finalmente en un monitor [50].

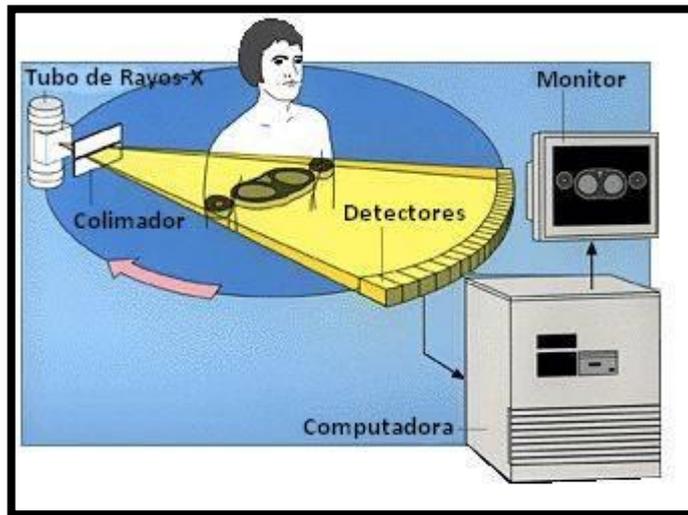


Figura 1.4. Imagen explicativa de la generación de una imagen TC. Extraído de [50].
En la **Figura 1.5** se aprecia un escaneo CT con presencia de neumonía.



Figura 1.5. Escaneo CT que muestra consolidación en el lóbulo inferior izquierdo (flecha roja). Sospecha de neumonía. Extraído de [7].

1.3.3 Ultrasonido de tórax

El ultrasonido es una onda sonora cuya frecuencia excede el límite perceptible por el oído humano (más de 20.000 Hz), constituyendo un método muy utilizado sobre todo en el campo de la medicina. La emisión de este tipo de sonidos dirigidos hacia un cuerpo en estudio permite formar una imagen que se utiliza con fines de diagnóstico [45].

Este procedimiento es no invasivo debido a que no se perfora la piel ni se penetra físicamente en el cuerpo para el estudio, es confiable y la examinación es de bajo costo [6].

Para este procedimiento, se utiliza un transductor, que es colocado sobre el paciente, además se usa un gel especial que ayudará a mejorar el contacto con la piel [11].

Cuando el transductor se coloca sobre el tórax, las ondas ultrasónicas atraviesan la piel y otros tejidos del cuerpo hasta llegar a los órganos y estructuras del tórax. Las ondas sonoras rebotan en los órganos como un eco y regresan al transductor. El transductor recoge las ondas reflejadas, que luego se convierten en una imagen electrónica de los órganos [10]. Ver **Figura 1.6.**

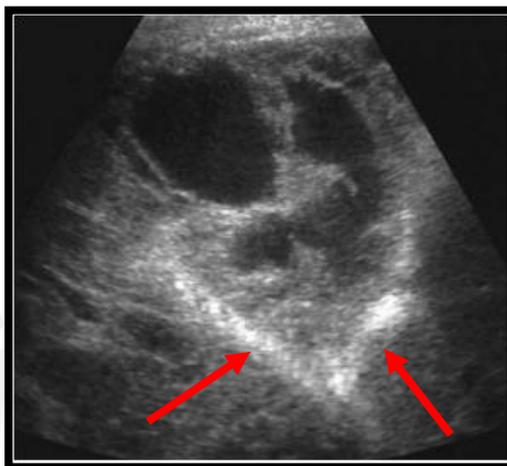


Figura 1.6. Imagen de ultrasonido de un empiema, que ocurre como consecuencia de una complicación de neumonía bacteriana en un niño de 7 años. Se aprecian artefactos hiperecoicos (señalados con flechas rojas) causados por la presencia de fluido en la cavidad pleural. Extraído de [4].

1.4 Estado del arte

En los últimos años, el uso de ultrasonografía se ha incrementado considerablemente debido a la portabilidad de los equipos y a que es un método no invasivo e inocuo. Por tal motivo, ha sido utilizado en la detección de diversas enfermedades respiratorias, entre las que se encuentra la neumonía, a través del diagnóstico médico, permitiendo obtener una sensibilidad entre 86 y 100%, y especificidad entre 84 y 100% [17,18]. En la **Tabla 1.1** se muestran un resumen de las enfermedades que han sido diagnosticadas con este método.

Estos resultados permiten apreciar lo útil que resulta el uso de ultrasonido en el diagnóstico de neumonía. Es por ello que se han desarrollado algunos métodos automáticos de descarte de la enfermedad mediante el estudio de la presencia de líneas A (reverberaciones generada por el transductor en un

medio con presencia de aire, es decir, en un pulmón sano) en pacientes sin padecimiento de neumonía, a partir de imágenes de ultrasonido [18].

La exactitud obtenida a partir de los métodos de umbralización y flujo óptico usados en el algoritmo mencionado, fue mayor al 75%. Sin embargo, se recomienda el desarrollo de nuevos métodos de detección de neumonía que brinden un resultado con un porcentaje de exactitud más alto.

Tabla 1.1. Artefactos de ultrasonido encontrados en los pulmones y su correspondiente enfermedad. Extraído de [13, 14, 15, 16].

Diagnóstico	Artefactos de ultrasonido encontrados	Sensibilidad (%)	Especificidad (%)	Exactitud (%)
Consolidación alveolar	–	93–94	98–100	97
Edema pulmonar	Líneas B difusas	86–97	94–98	–
Embolismo pulmonar	Líneas A (+) embolismo venoso	81	99	–
	Lesiones en la periferia	80	92	84
Neumonía	Líneas B + desaparición del deslizamiento pulmonar	11	100	–
	Líneas A en pulmones + líneas B en la parte contralateral del pulmón	14	100	–
	Consolidación alveolar	11	99	–

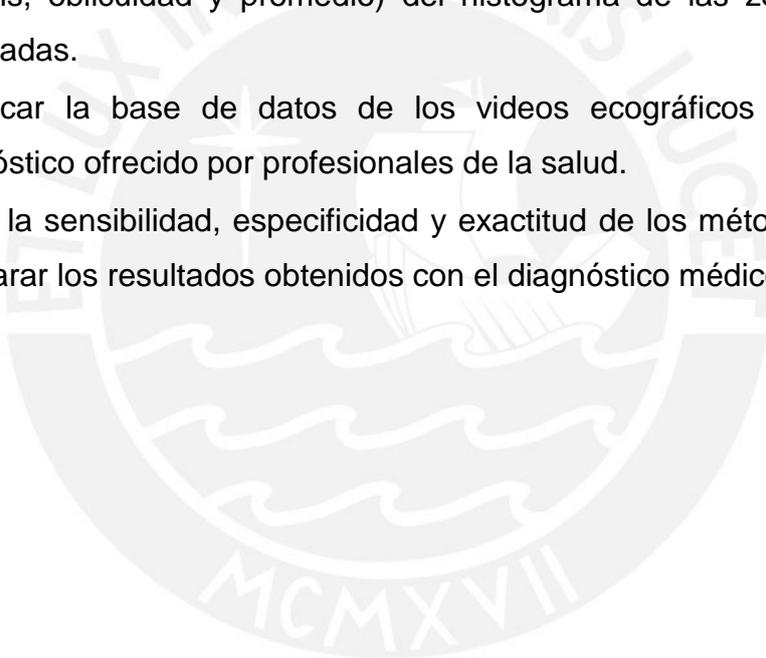
1.5 Objetivos

GENERAL:

Desarrollar un algoritmo que detecte la presencia de líneas B en imágenes de ultrasonido para la prevención de neumonía en poblaciones pediátricas menores a 5 años.

ESPECÍFICOS:

- Detectar automáticamente las regiones intercostales, que constituyen las zonas de interés dentro de las imágenes de ultrasonido, a partir de las cuales se realizará el análisis.
- Desarrollar un algoritmo que permita diferenciar la presencia de líneas B analizando las características matemáticas (energía, desviación estándar, curtosis, oblicuidad y promedio) del histograma de las zonas de interés detectadas.
- Clasificar la base de datos de los videos ecográficos de acuerdo al diagnóstico ofrecido por profesionales de la salud.
- Hallar la sensibilidad, especificidad y exactitud de los métodos utilizados y comparar los resultados obtenidos con el diagnóstico médico.



CAPÍTULO 2: Terminología básica e información sobre el procesamiento de imágenes

El presente capítulo abordará los conceptos, fórmulas y herramientas básicas para el entendimiento del método desarrollado.

2.1 Sonda ultrasónica

Es el instrumento que se utiliza para la transmisión y recepción del ultrasonido. Tiene contacto directo con el paciente, y de acuerdo a la zona del cuerpo que se coloque, se obtendrá la imagen requerida.

En las aplicaciones prácticas de toma de imágenes de pecho, la sonda suele trabajar en dos bandas de frecuencias (3.5 a 5 MHz) o (5 a 10 MHz). Las sondas de alta frecuencia son óptimas para visualizar estructuras que se encuentran a menor profundidad, como la pleura.

2.2 Formación de una imagen de ultrasonido

Las imágenes ultrasónicas se forman a partir de las ondas mecánicas generadas por la resonancia de los cristales que se encuentran en un transductor debido al efecto piezoeléctrico.

Este fenómeno genera un potencial eléctrico en las caras del cristal dentro del transductor, al deformarlo mecánicamente. El mismo fenómeno puede presentarse de manera inversa, es decir, que si se aplica una tensión eléctrica en las caras del cristal interno, este experimentará deformaciones mecánicas y vibraciones.

Esta es la propiedad en que se basa el funcionamiento de la sonda o transductor ecográfico. La sonda recibirá impulsos eléctricos que serán transformados en pulsos acústicos, los cuales serán transmitidos. De manera inversa, recibirá los pulsos acústicos (ecos) provenientes de las zonas del cuerpo en este caso, para luego convertirlos nuevamente en impulsos eléctricos que se manifestarán en imágenes vistas a través del ecógrafo [20].

Cuando la onda ultrasónica va viajando a través de los diferentes medios, será reflejada o refractada de acuerdo a las propiedades del medio que atraviesa. Parte de la onda, es reflejada y regresa al transductor convirtiéndose en corriente eléctrica. Dentro del circuito receptor se calcula la profundidad de los tejidos a partir del tiempo de retorno, mientras que la

amplitud de la onda de retorno permitirá calcular la intensidad en la escala de grises. De este modo, mientras más débil sea un eco (no se refleja totalmente la onda) el nivel de gris será más negro, y por el contrario, si el eco es más potente (gran parte de la onda reflejada) el nivel de gris será más claro.

Representación de imágenes de ultrasonido:

2.2.1 Modo A: (Modo de amplitud)

Constituye la forma más simple de representación debido a que se grafica el voltaje (amplitud del eco de retorno a la sonda proveniente del cuerpo en estudio) en función del tiempo. De este modo se busca obtener la profundidad del tejido y la separación que existe entre ellos.

2.2.2 Modo B: (Modo de brillo)

Consiste en el procesamiento y ordenamiento lateral de líneas en modo A espacialmente colindantes. Esta agrupación se convierte en una matriz cuya amplitud, representada por el brillo, es directamente proporcional a la intensidad del eco del regreso [21]. Ver **Figura 2.1**.

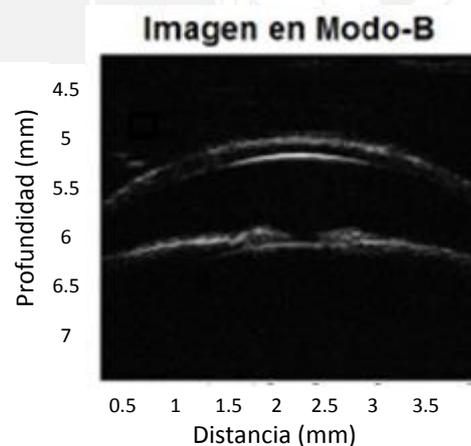


Figura 2.1. Imagen Modo-B formado a partir de líneas en modo A procesadas.
Extraído de [21].

2.3 Características del pulmón en la imagen de ultrasonido

2.3.1 Líneas A:

Se diferencian de las líneas A de ultrasonido (presentes en el modo A), porque a diferencia de estas, que representan niveles de voltaje del eco de recepción en la sonda, las líneas A se van a visualizar en la imagen ecográfica como parte del pulmón.

La discriminación entre imágenes de tórax correspondientes a un paciente sano y a uno enfermo es posible gracias a las características y artefactos presentes en las imágenes de ultrasonido. En la imagen de un pulmón normalmente aireado, se muestra primero la línea pleural hiperecoica (la cual representa la ubicación de la pleura, que es la capa que recubre y protege los pulmones) seguida de líneas casi paralelas espaciadas regularmente, las cuales son denominadas “líneas A”. Estas son producidas por el reflejo de la línea pleural y aparecen proyectadas a múltiples distancias de la superficie de la línea pleural [22]. Ver **Figura 2.2**.

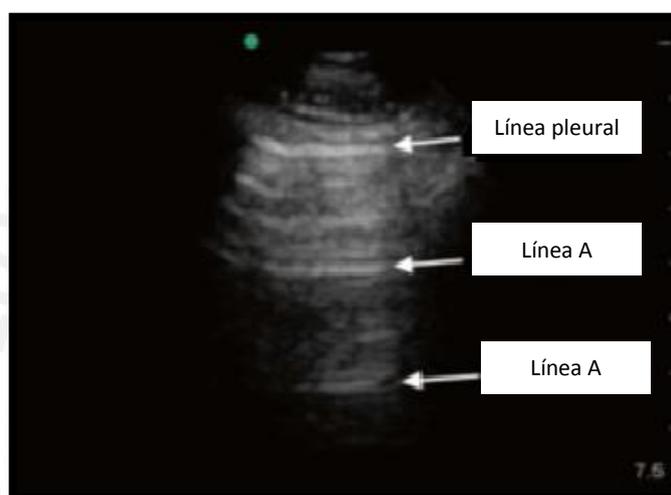


Figura 2.2. Líneas A en un pulmón sano. Adaptado de [11].

2.3.2 Líneas B (llamadas también colas de cometa)

Una alteración en la normal aeración de los pulmones genera resultados anormales en las imágenes de ultrasonido. Esto se puede apreciar en un incremento de artefactos verticales que crecen desde la línea pleural y son denominados “Líneas B” [20]. Ver **Figura 2.3**.

Las líneas B son artefactos verticales que aparecen por la presencia de líquido en los órganos, en este caso de los pulmones. Al igual que las líneas A de neumonía, estas se muestran desde la línea pleural (localizada en la parte superior de la imagen), pero a diferencia de ellas, se extienden de forma vertical hacia la parte inferior de la imagen. La intensidad de las líneas B se incrementa con los movimientos de inspiración, de esta forma se nota una variación en su presencia, ya que aparecen y desaparecen de la imagen de ultrasonido. Con la presencia de líneas B, las líneas A desaparecen, ya que no hay una aireación normal en el pulmón [23].

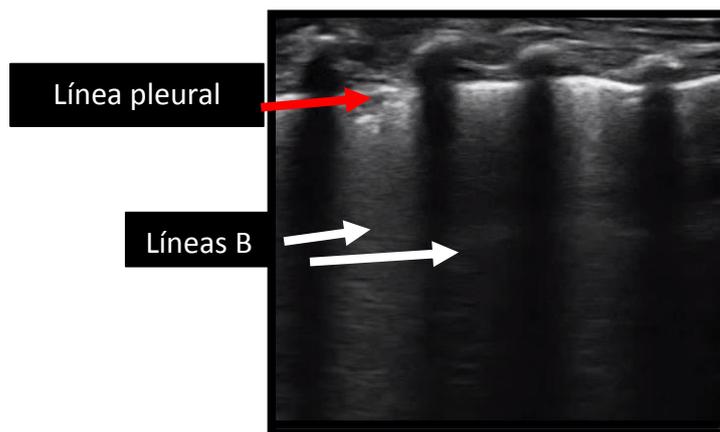


Figura 2.3. Línea pleural (flecha roja). Líneas B (flechas blancas) en un paciente con neumonía. Elaboración propia.

2.3.3 Deslizamiento pulmonar y pulso pulmonar

La superficie pleural de un pulmón lleno de aire se puede visualizar a través del ultrasonido. La pleura aparece como una estructura lineal hiperecoica que se mueve en concordancia con el ciclo respiratorio (denominado deslizamiento pulmonar) [24] o el ciclo cardíaco (denominado pulso pulmonar) [25].

2.4 Procesamiento de la imagen digital

2.4.1 Preparación de la muestra:

El grupo de muestras consiste de 15 videos de pacientes sanos y 15 videos de pacientes enfermos de neumonía. Todos los pacientes son niños con edades comprendidas entre 6 meses y 5 años. Dichos videos fueron otorgados por el Instituto Nacional de Salud del Niño (INSN) ubicado en Lima, Perú.

Las muestras fueron tomadas de los espacios intercostales de los pacientes con el escáner de ultrasonido SonixTOUCH de Analogic Ultrasound (Peabody, MA, USA). Dicho escáner contaba con un transductor lineal L14-5 del mismo fabricante, el cual trabajaba a una frecuencia central de 6.6 MHz. Los videos fueron tomados a una profundidad máxima de análisis de 4cm. Dichos videos tienen una duración promedio de 7 segundos, y el análisis, se realizó cuadro por cuadro.

2.4.2 Extracción de características del histograma

Histograma de una imagen digital:

El histograma de una imagen digital se define como un gráfico donde se representa un cierto rango de intensidades de color y las cantidades de píxeles que hay para cada uno de esos niveles de color. Para las imágenes de 8 bits en escala de grises, la cantidad de niveles de color, que hay por defecto, es de 256. En la **Figura 2.4** se aprecia la imagen de un histograma.

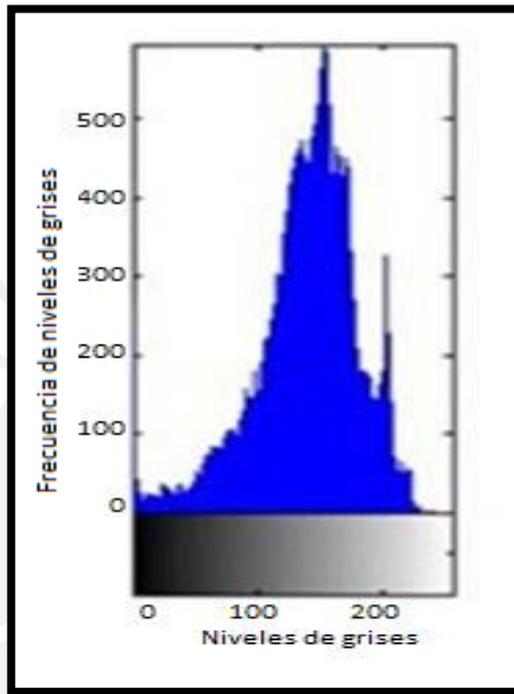


Figura 2.4. Histograma de una imagen digital. Extraído de [29].

El histograma se define como [31]:

$$H(i) = \frac{n_i}{N}, i = 0, 1, \dots, L - 1$$

Donde:

i = nivel de gris

L = número de niveles de grises (256)

n_i = cantidad de píxeles con nivel i

N = número total de píxeles de una imagen.

Para este procedimiento, se extraerán los histogramas de cada espacio intercostal en cada cuadro del video y se extraerán las siguientes características matemáticas: valor promedio, desviación estándar, oblicuidad, curtosis y energía.

a) Valor promedio

Representa el valor promedio de la intensidad de gris en un espacio de estudio determinado [29]. El valor promedio se define como:

$$\mu = \sum_{i=0}^{L-1} iH(i)$$

Donde:

μ = Valor promedio

L = cantidad de niveles de grises

i = nivel de gris específico

$H(i)$ = valor del histograma en i

b) Desviación estándar

Corresponde a la raíz cuadrada de la varianza, la cual refleja la distribución discreta numéricamente de una imagen en escala de grises [29]. El cálculo de la desviación estándar para un histograma es descrito por:

$$\sigma = \sqrt{\sum_{i=0}^{L-1} (i - \mu)^2 H(i)}$$

Donde:

σ = Desviación estándar

c) Oblicuidad

Es una medida de asimetría de la distribución de las muestras [29].

Si es menor que 0, la mayoría de los datos se encuentra a la izquierda de la media.

Si es mayor que 0, la mayoría de los datos se encuentra a la derecha de la media.

Si es igual que 0, se dice que los datos están distribuidos simétricamente.

El cálculo de la oblicuidad para un histograma es descrito por:

$$\mu_s = 1/\sigma^3 \sum_{i=0}^{L-1} (i - \mu)^3 H(i)$$

Donde:

$\mu_s = \text{Oblicuidad}$

d) Curtosis

Mide si la distribución de la imagen en escala de grises está concentrada cerca al valor promedio. Mientras menor sea el valor, implica que está más concentrado en el valor promedio [29].

El cálculo de la curtosis para un histograma es descrito por:

$$\mu_k = 1/\sigma^4 \sum_{i=0}^{L-1} (i - \mu)^4 H(i)$$

Donde:

$\mu_k = \text{Curtosis}$

e) Energía

Refleja el grado de uniformidad de la distribución del histograma. A mayor valor de energía, más uniformidad representa [29].

El cálculo de la energía para un histograma es descrito por:

$$\mu_N = \sum_{i=0}^{L-1} H(i)^2$$

Donde:

$\mu_N = \text{Energía}$

2.4.3 Definición de herramientas en el desarrollo del algoritmo

2.4.3.1 Matriz binaria: Conocida como matriz booleana. Es aquella cuyos elementos son únicamente '1's y '0's [32].

2.4.3.2 Interpolación con spline cúbico

La idea de la interpolación es poder estimar $f(x)$ para un x arbitrario, a partir de la construcción de una curva o superficie que une los puntos donde se han realizado las mediciones y cuyo valor sí se conoce. Se asume que el punto arbitrario x se encuentra dentro de los límites de los puntos de medición, en caso contrario se llamará extrapolación [33].

El objetivo de los splines cúbicos es generar una función de interpolación que tenga una primera derivada suavizada y una segunda derivada continua, tanto dentro de los intervalos como en los puntos que se encuentran fuera de ellos [33].

En este trabajo se utilizó spline cúbico de Matlab por contener la curva más exacta para la aproximación de la pleura (discutido más adelante en inciso **2) de la sección 3.2.2**).

2.4.3.3 Umbralización

El procedimiento de umbralización es caracterizado por:

$$g(x, y) = \begin{cases} 1, & \text{si } f(x, y) > T \\ 0, & \text{si } f(x, y) \leq T \end{cases}$$

Donde:

$g(x, y)$ = Imagen binaria de salida

$f(x, y)$ = Imagen de entrada en escala de grises

T = valor umbral que determina si el pixel de salida será 1 o 0

El resultado de este proceso dará como resultado una matriz binaria, dependiendo del valor umbral que se haya considerado [34].

2.4.3.4 Centroide o centro de masa

Define el centro geométrico de un objeto [35], es decir el punto de equilibrio de un objeto. En este caso, el centroide se calculará en objetos planos (imágenes) para la sección *Detección automática de la línea pleural* (**sección 3.2.2**). El centro de masa se define por [36]:

$$x_{cm} = \frac{\sum_{i=1}^N m_i * x_i}{M}$$

Donde:

N = número de elementos del sistema

x_{cm} = posición del centro de masa

x_i = posición de cada una de las partículas que componen el sistema respecto al mismo sistema de referencia

M = masa total del sistema

m_i = masa de cada elemento que compone el sistema

2.4.3.5 Operación morfológica de apertura

Las operaciones morfológicas son útiles para simplificar las imágenes, es decir, eliminar ruido presente en ellas y destacar la estructura de los objetos. En particular, la operación de apertura aplica una erosión y luego una dilatación [34].

a) Erosión binaria

La técnica de erosión en una imagen está dada por:

$$A \ominus B = \{ z | (B)_z \subseteq A \}$$

Donde:

$A \ominus B$ = Erosión de A por B.

$z|(B)z$ = Conjunto de todos los puntos z contenidos en B trasladados por z.

Esta ecuación significa que la erosión de A por B es el conjunto de todos los puntos z tal que B, trasladado por z, está contenido en A [34].

b) Dilatación binaria

La técnica de dilatación en una imagen consiste en la operación:

$$A \oplus B = \{ |(B)_z \subseteq A \}$$

Donde:

$A \oplus B$ = Dilatación de A en B.

$z|(\hat{B})z$ = Conjunto de todos los desplazamientos de z en el reflejo de B.

Esta ecuación significa que la dilatación de A por B es el conjunto de todos los desplazamientos de z tal que el reflejo de B y A se superponen por al menos un elemento [34].

2.4.3.6 Máquina de vector de soporte

Máquina de vector de soporte es la traducción al español de *support vector machine* (SVM).

Es un método de aprendizaje automático ideal cuando los datos a analizar son de dos clases. Para lograr esto, es necesario entrenar al algoritmo con una muestra inicial, que le permita reconocer las características de cada clase, generando un clasificador que será usado en la data de interés. Este método clasifica los datos encontrando el mejor hiperplano que separa ambas clases existentes, es decir, tomando la distancia más larga de los elementos más cercanos al hiperplano. Los vectores de soporte serán aquellos datos que se encuentran más cerca al hiperplano [30]. Ver **Figura 2.5.**

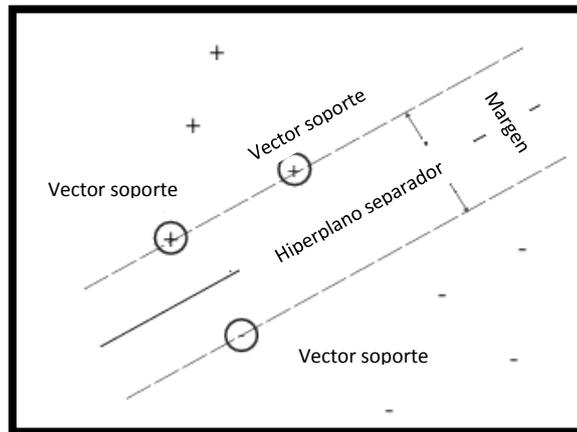


Figura 2.5. Hiperplano separando dos clases de datos. Con + indicando datos del tipo 1 y - indicando datos del tipo 2. Los vectores soporte se muestran encerrados en círculos. Adaptado de [30].

Son diversos los campos en los que han sido utilizadas con éxito, tales como visión artificial, reconocimiento de caracteres, categorización de texto e hipertexto, clasificación de proteínas, procesamiento de lenguaje natural, etc. permitiendo afirmar su amplia propagación en problemas de discernimiento de clases [46].

Las máquinas de vectores soporte se basan en el uso de kernels, los cuales son algoritmos que definen similitudes entre los elementos de un conjunto a ser clasificado. Sean los datos $(x_1, y_1) \dots \dots \dots (x_m, y_m) \in X\{\pm 1\}$.

Los datos x_i son los que se quieren clasificar y y_i corresponden a las etiquetas que caracterizan a cada dato [48].

Se observa que $x \in X$ y se quiere predecir $y \in \{\pm 1\}$. Para ello, se usará una medida de similitud en X y en $\{\pm 1\}$. En SVM se utiliza la siguiente medida de similitud:

$$K: X \times X \rightarrow R$$

$$(x, x') \rightarrow K(x, x')$$

Lo cual significa que se debe encontrar una función tal que dados dos valores x, x' devuelva un valor real que permita caracterizar su similitud. A esta función es a la que llamaremos 'función kernel'. La medida de similitud más usada en SVM es el producto escalar [48]. Por ejemplo, sean los valores $x, x' \in R$, el producto punto se define como sigue:

$$(x, x') = \sum_{i=1}^N (x_i) \cdot (x'_i)$$

Donde:

x_i = entrada i-ésima del vector.

En la presente tesis, se analizarán los videos de ultrasonido para la clasificación de espacios intercostales a partir de las 3 principales clases de kernel definidas a continuación.

Tipos de kernel [49]:

- 1) Lineal: El hiperplano usado es una línea recta que separa los datos en dos clases. El kernel lineal se define como el producto punto y se observa en:

$$K(x_i, y_j) = x \cdot y$$

Uno de los parámetros importantes a definir es 'C' ('*box constraint*'), el cual significa una penalización para los datos mal clasificados. Si este parámetro es pequeño, la clasificación es menos estricta (mayor cantidad de vectores soporte), y a medida que su valor aumenta, la clasificación se torna más restringida (menos vectores soporte). Ver

Figura 2.6.

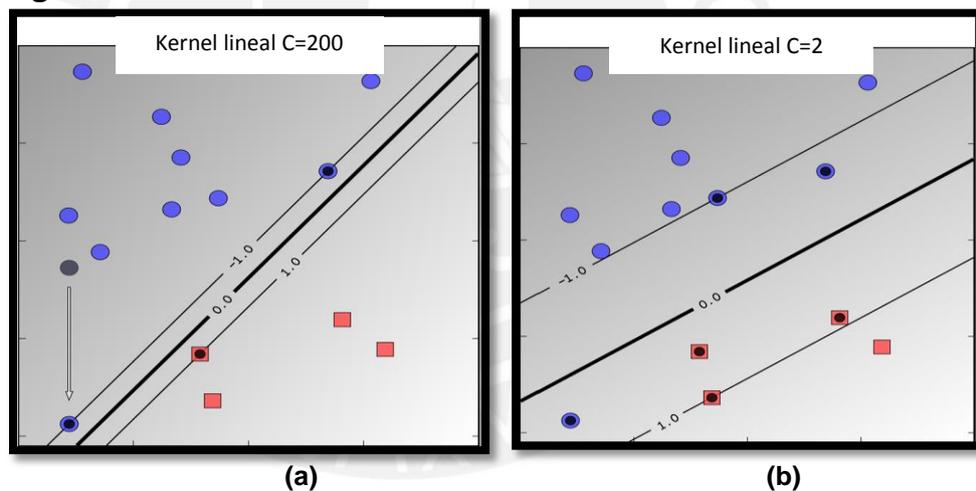


Figura 2.6. Comparación entre 2 clasificaciones lineales con diferentes valores de C. En (a) apreciamos una menor cantidad de vectores soporte (remarcados con puntos negros), mientras que en (b) la cantidad de vectores soporte aumenta. Adaptado de [47].

- 2) Polinomial: Similar al kernel lineal pero considerando su grado polinomial. Está definido por:

$$K(x_i, y_j) = (x \cdot y + 1)^n$$

Donde:

n = grado del polinomio.

Un parámetro importante es el grado del polinomio, ya que de acuerdo a eso variará la curva del hiperplano para la clasificación [48]. Ver **Figura 2.7**.

- 3) Función de base radial (radial basis function-rbf): Se define su ecuación exponencial a continuación:

$$K(x_i, y_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

Dos parámetros importantes para definir en este kernel son: 'C' (box constraint) y σ (sigma). El parámetro sigma se encargará de definir qué tan curvo será el hiperplano, es decir un valor de sigma alto hará que el kernel sea casi lineal, mientras que un valor bajo lo hará más curvo [48]. Ver **Figura 2.8**.

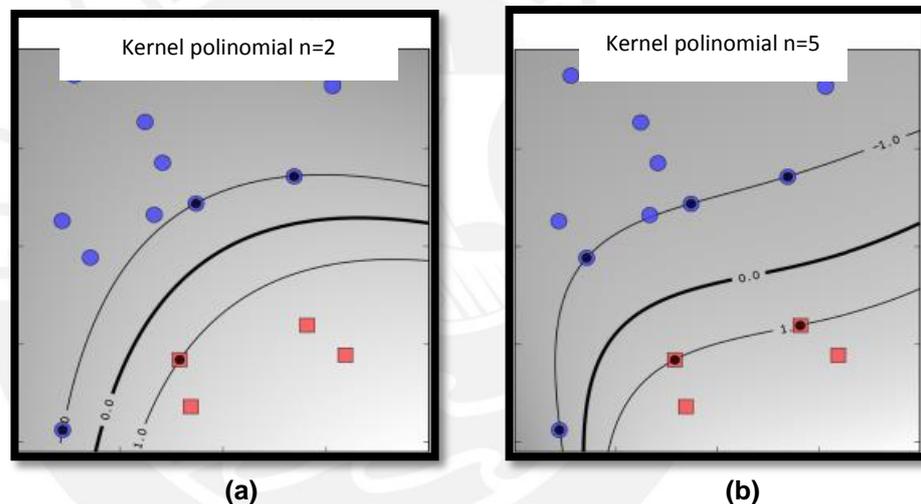


Figura 2.7. Comparación entre dos kernels polinomiales de grados $n=2$ y $n=5$ para (a) y (b) respectivamente. Adaptado de [47].

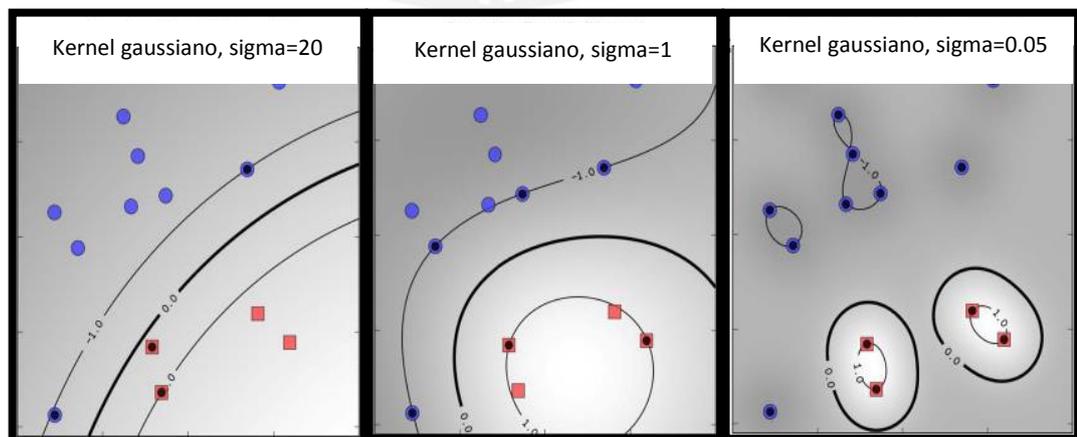


Figura 2.8. Clasificación rbf con diferentes valores de sigma. Se aprecia la variación de curvatura que experimenta el hiperplano. Adaptado de [47].

2.4.3.7 Análisis de componentes principales

Análisis de componentes principales es la traducción al español de *principal component analysis* (PCA).

Es un método cuantitativo que consiste en la reducción de la cantidad de variables cuando se realizan estudios multivariados, generando un nuevo conjunto de ellas, denominadas “componentes principales”. Cada una de esas nuevas componentes es la combinación lineal de las variables originales, y son ortogonales entre sí, de manera que la información que brinden, no sea redundante. Todas las componentes principales en su conjunto, forman una base ortogonal para la distribución de los datos, y habrá tantas como variables originales haya [51].

Método de generación de las componentes principales:

- 1) Definir el conjunto de datos a estudiar, de manera que tengamos un cierto número de filas (observaciones) y que por cada una de ellas haya más de 1 variable descriptiva (multivariable). Además, se debe calcular el valor promedio, y extraer ese valor de cada observación.
- 2) Calcular la matriz de covarianza, la cual nos indica el grado de variación conjunta de dos o más variables aleatorias respecto a sus medias. Es el dato básico para determinar si existe una dependencia entre ambas variables. La covarianza para dos dimensiones define su ecuación en [51]:

$$cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n-1)}$$

Donde:

$cov(X, Y)$: Covarianza de las variables X e Y.

n : Número total de elementos de X e Y.

\bar{X} : Promedio de valores de X.

\bar{Y} : Promedio de valores de Y.

- 3) Calcular los vectores propios y valores propios de la matriz de covarianza [51]. Los vectores propios serán las nuevas componentes creadas a partir de las variables originales; siendo las componentes principales, aquellas que tengan los mayores valores propios. Por lo general se usan las dos primeras componentes principales debido a su mayor significado en los datos originales, permitiendo tener menos

dimensiones de análisis cuando la data de entrada posee de 3 a más variables.

2.5 Análisis de datos y resultados

2.5.1 Análisis de datos

Los datos de estudio se separarán en conjunto de entrenamiento y conjunto de prueba. Al ser 30 videos, se escoge el primer video como conjunto de prueba y los restantes 29 como el conjunto de entrenamiento. Luego, se escoge el segundo video como conjunto de prueba y los 29 restantes como conjunto de entrenamiento y así sucesivamente hasta tener los resultados de 30 conjuntos de prueba, los cuales serán promediados para obtener los resultados finales. Este método es conocido como el método “dejando uno fuera” (por la traducción al español de *Leave one out*). Ver **Figura 2.9**.

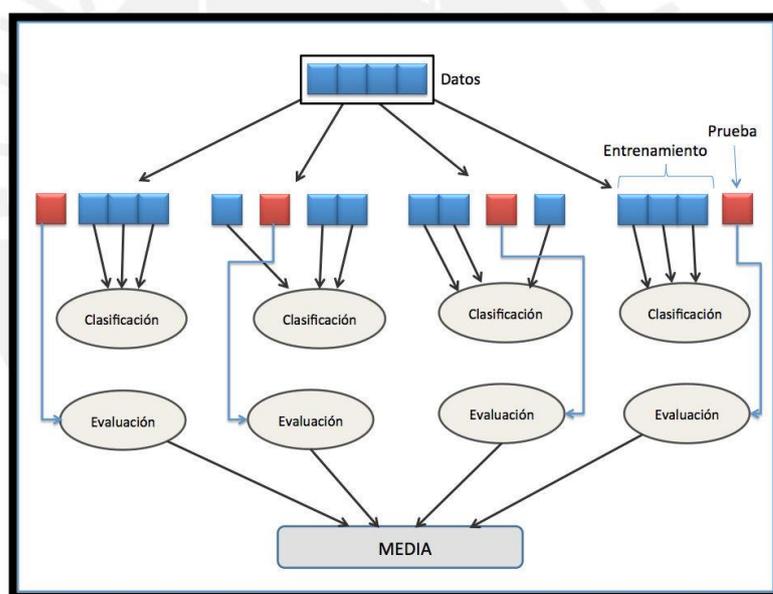


Figura 2.9. Esquema de método *leave one out* para analizar los datos de entrada.
Extraído de [52].

2.5.2 Análisis de resultados

Los resultados obtenidos en el presente trabajo se evaluarán según la siguiente clasificación [26]:

- Verdadero Positivo (VP): Espacio intercostal enfermo detectado como enfermo.
- Falso Positivo (FP): Espacio intercostal sano detectado como enfermo.

- Verdadero Negativo (VN): Espacio intercostal sano detectado como sano.
- Falso Negativo (FN): Espacio intercostal enfermo detectado como sano.

2.5.2.1 Sensibilidad

Representa el porcentaje de espacios intercostales diagnosticados como enfermos por el algoritmo, entre la cantidad de espacios intercostales enfermos [26]. Su ecuación se muestra en:

$$S(\%) = \frac{VP}{VP + FN} * 100$$

2.5.2.2 Especificidad

Es el porcentaje de espacios intercostales diagnosticados como sanos por el algoritmo, entre la cantidad de espacios intercostales sanos [26]. Su ecuación se muestra en:

$$E(\%) = \frac{VN}{VN + FP} * 100$$

2.5.2.3 Exactitud

Es el porcentaje de espacios intercostales correctamente identificados como sanos o enfermos por el algoritmo entre la cantidad total de espacios intercostales que han sido procesados [26]. Su ecuación se muestra en:

$$A(\%) = \frac{VP + VN}{VP + VN + FP + FN} * 100$$

2.5.2.4 Curvas ROC (Receiver Operating Characteristic)

Fueron introducidas en la investigación clínica por los radiólogos Hanley y McNeil. En ellas se representa la sensibilidad en función de los falsos positivos (complemento de la especificidad) para distintos puntos de corte [27]. Ver **Figura 2.10**.

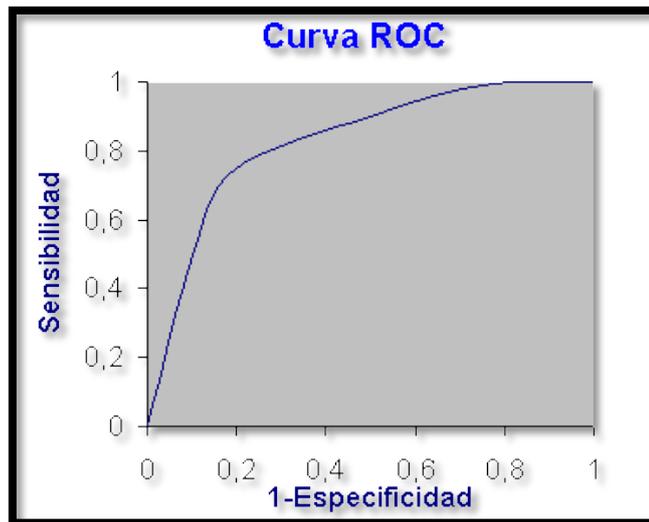


Figura 2.10. Curva ROC de una prueba de diagnóstico hipotético. Extraído de [27].

Si la prueba fuera perfecta, la sensibilidad y especificidad serían 1, por lo tanto, la curva contendría el par ordenado (0,1) que va a representar su punto extremo superior izquierdo.

En cambio, si la prueba resulta inservible, la curva estará en la diagonal de (0,0) a (1,1).

El indicativo general que permitirá observar si una prueba es útil o no es el área bajo la curva (AUC), que tendrá valores entre 1 (prueba útil) y 0,5 (prueba no útil) [28].

CAPÍTULO 3: Metodología usada antes y durante la implementación del algoritmo de detección de la enfermedad.

En el presente capítulo se describirán los pasos y consideraciones previas que debieron tomarse antes del desarrollo del algoritmo y la secuencia seguida para la implementación del mismo.

3.1 Adquisición de la base de datos en pacientes y consideraciones necesarias para dicha adquisición

La base de datos a analizar fue recolectada por médicos del Instituto Nacional de Salud del Niño (INSN), localizado en Lima, Perú, en un estudio previo que se realizó sobre el diagnóstico de neumonía en niños comprendidos en el rango de edad de 6 meses a 5 años con una edad promedio de 3 años \pm 3 meses, usando ultrasonido [19]. Dicha muestra consta de 30 videos (15 videos de pacientes sanos y 15 videos de pacientes enfermos) clasificados por un médico especialista, previamente. Al ser menores de edad, el permiso para la toma de muestra de cada uno de los pacientes fue firmado por sus respectivos padres y validado por el **comité de ética del INSN**, explicándoles previamente que los pacientes estaban participando de un estudio de diagnóstico de neumonía en donde se les realizaría una ecografía en la zona torácica.

El protocolo de adquisición de la base de datos fue grabar doce videos por paciente, en un total de 31 pacientes, correspondientes a la división del tórax representada por las secciones: anterior, lateral o posterior; superior o inferior y derecha o izquierda. Sin embargo, se descartaron aquellos videos que presentaron fallas de origen en la adquisición, quedándonos con los 30 videos ya mencionados.

En la **Figura 3.1** se observa un ejemplo de la división en la zona anterior. Para la zona posterior, las secciones son las mismas, y para las zonas laterales solo se considera superior e inferior.



Figura 3.1. División del tórax de la zona anterior. Adaptado de [53].

Para la toma de cada video, el paciente fue ubicado en posición decúbito supino, decúbito lateral sobre la camilla o en los brazos de sus padres, dependiendo de su edad.

El equipo usado para la adquisición fue el escáner de ultrasonido SonixTOUCH de Analogic Ultrasound (Peabody, MA, USA), que pertenece al Laboratorio de Imágenes Médicas (LIM) de la Pontificia Universidad Católica del Perú (PUCP); el cual fue trasladado al INSN para el estudio mencionado. Las imágenes fueron tomadas con un transductor lineal L14-5 que trabaja a una frecuencia central de 6.6 MHz. Del mismo modo, las imágenes se tomaron a una profundidad máxima de análisis de 4cm. Los videos obtenidos tienen una duración aproximada de 7 segundos con una frecuencia de muestreo de 30 cuadros por segundo. Para su posterior análisis fueron separados en cuadros (imágenes) de video, siendo la resolución de cada uno de 462x451 pixeles.

3.2 Secuencia del procedimiento usado en el algoritmo

La implementación del algoritmo de detección de la enfermedad, consta de un procesamiento previo en el cual se acondicionará la base de datos para que resulte más fácil la manipulación de los mismos a través del software. A continuación, el procedimiento se explica con un diagrama de bloques en la **Figura 3.2.**

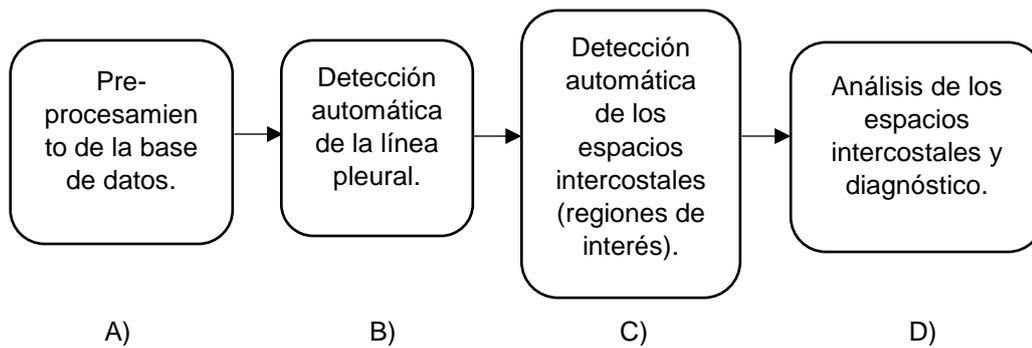


Figura 3.2. Diagrama de bloques de la secuencia del algoritmo.

Cabe resaltar que los pasos arriba mencionados son ejecutados a cada uno de los videos, y dentro del procedimiento para cada video, se analizará cuadro por cuadro.

3.2.1 Pre-procesamiento de la base de datos (A)

En esta etapa se adaptarán los videos de manera que el programa procese los datos de manera más sencilla. El procedimiento se aplicará a cada uno de los cuadros que conforman un video.

1. Lectura de los videos

Cada video ecográfico es leído cuadro a cuadro por el software, de manera que se obtengan los cuadros que le pertenecen a cada uno.

2. Restricción manual del área a analizar

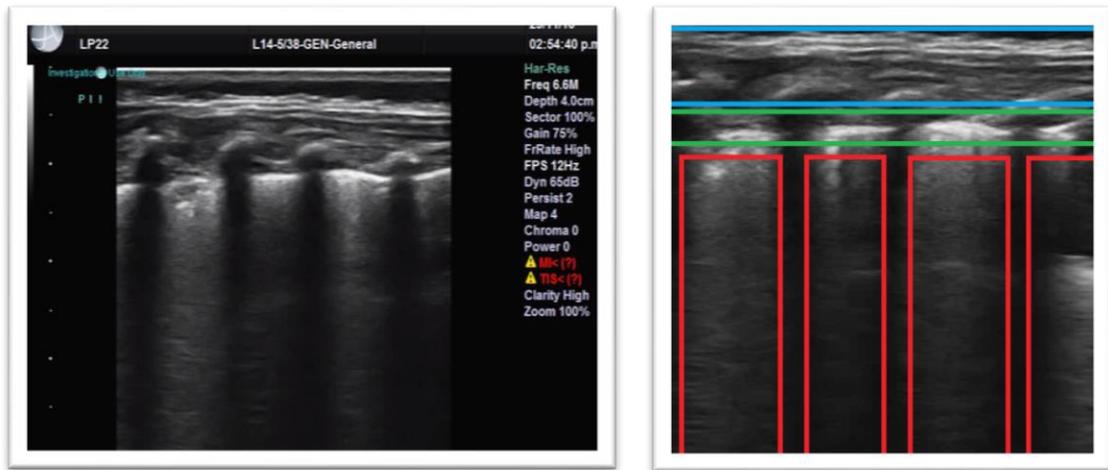
En cada cuadro de video hay áreas que no serán consideradas porque son parte de la interfaz de visualización. Cada cuadro de video tiene una resolución de 600x800 pixeles que se recortará a una nueva resolución de 462x451, tal como se indica en la **Figura 3.3**.

3.2.2 Detección automática de la línea pleural (B)

La línea pleural es la parte que recubre al pulmón y lo protege dentro de la cavidad torácica. La detección de la línea pleural será el punto de partida para la delimitación de los espacios intercostales.

1. Segmentación de las áreas que conforman la pleura en una sola máscara (Primera parte)

El orden de los pasos que se siguieron en la implementación de este algoritmo fue establecido heurísticamente hasta lograr obtener la segmentación requerida. Dicho orden es importante, ya que, de otro modo, el procedimiento arroja una segmentación errónea del área que se busca.



(a)

(b)

Figura 3.3. (a) Cuadro sin procesar. (b) Cuadro recortado. Se aprecian en la imagen, tejido adiposo y tejido muscular (encuadre celeste), la línea pleural (encuadre verde) y los espacios intercostales (encuadres rojos).

Las herramientas de procesamiento usadas fueron: umbralización, cálculo del centroide de la imagen, operación morfológica de apertura, operación OR entre imágenes y clasificación de acuerdo a las dimensiones (área y largo) de los objetos dentro de la imagen.

a) Umbralización de cada cuadro de video

En el video ecográfico, la línea pleural se puede apreciar como una línea brillante (hiperecogénica); por lo tanto, el primer paso para su segmentación será una umbralización del 50% (ver **Figura 3.5**). De esta manera, nos aseguramos de que solo se consideren las regiones más brillantes del cuadro, entre las que se encuentra la pleura. Sin embargo, aún hay información no deseada que debe ser extraída, como la parte del tejido que se encuentra en la parte superior y los ecos producidos por la línea pleural. El principal objetivo en los siguientes pasos será diferenciar la línea pleural del tejido adiposo y muscular, y las reverberaciones de la pleura, que también constituye una zona hiperecogénica, como se muestra en la **Figura 3.4**.

b) Eliminación de regiones de acuerdo a sus áreas

Solo se conservarán aquellas zonas cuyas áreas tengan un valor mayor que el promedio. Esto se debe a que hay zonas con áreas pequeñas que, en este caso, no forman parte del objeto en estudio. Ver **Figura 3.6**

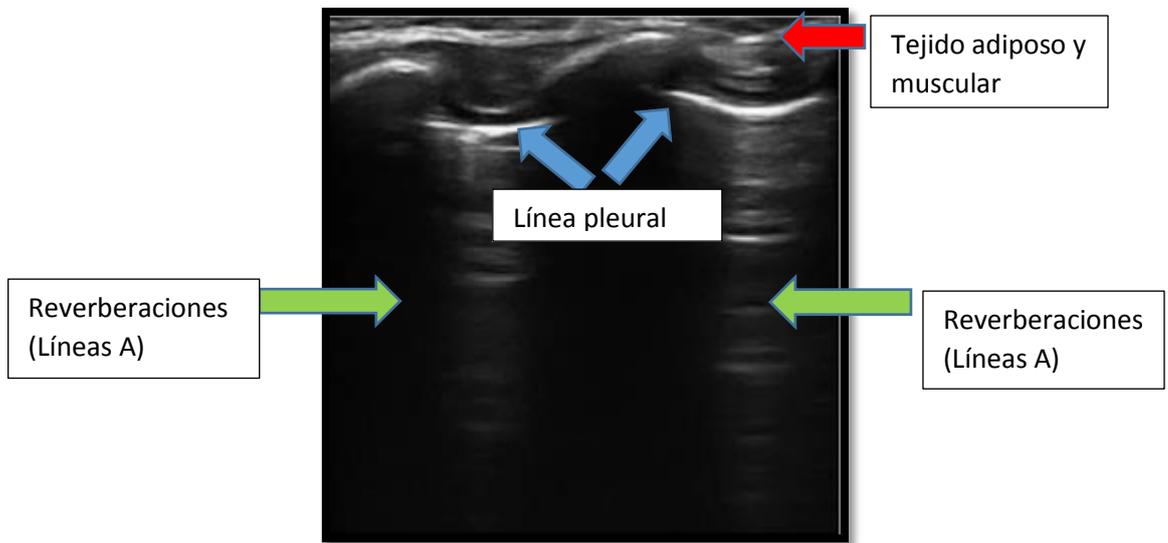


Figura 3.4. Cuadro de video de un paciente diagnosticado como sano. La flecha roja indica el tejido en la cavidad torácica que colinda al pulmón. Las flechas azules indican la línea pleural. Y las flechas verdes señalan las reverberaciones producidas por la pleura en un pulmón normalmente aireado.

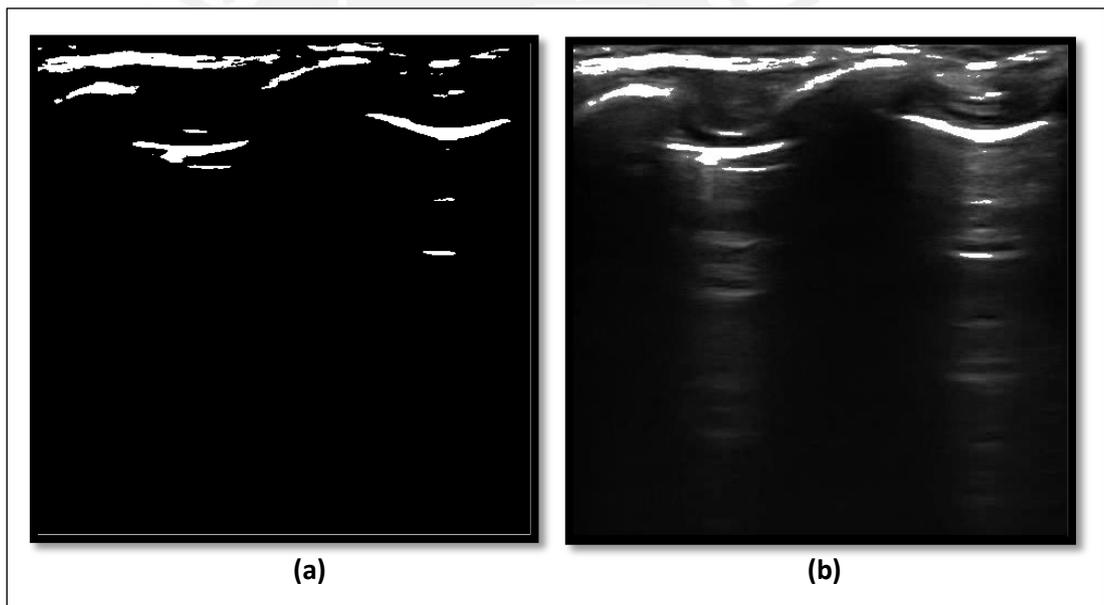


Figura 3.5. (a) Imagen binaria de la umbralización de un cuadro de video considerando solo el 50% (b) Comparación del cuadro de video original con su umbralización.

c) Filtrado de las regiones por su posición respecto al centroide de cada cuadro de video

El siguiente paso se basa en considerar únicamente a las regiones que se encuentran debajo del centroide de la imagen, pues geoméricamente, la pleura siempre estará como uno de los últimos elementos. Ver **Figura 3.7.**

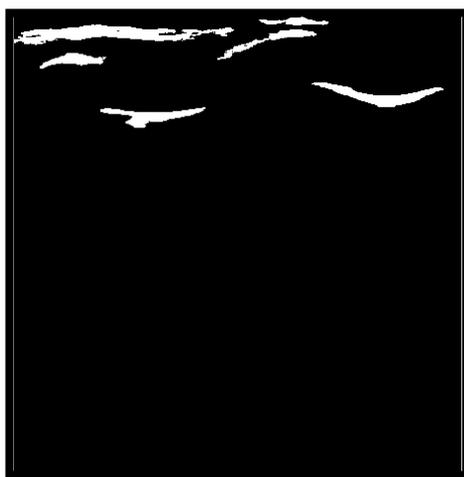


Figura 3.6. Imagen binaria del cuadro de video sin áreas más pequeñas. Se aprecia la pleura y parte del tejido.

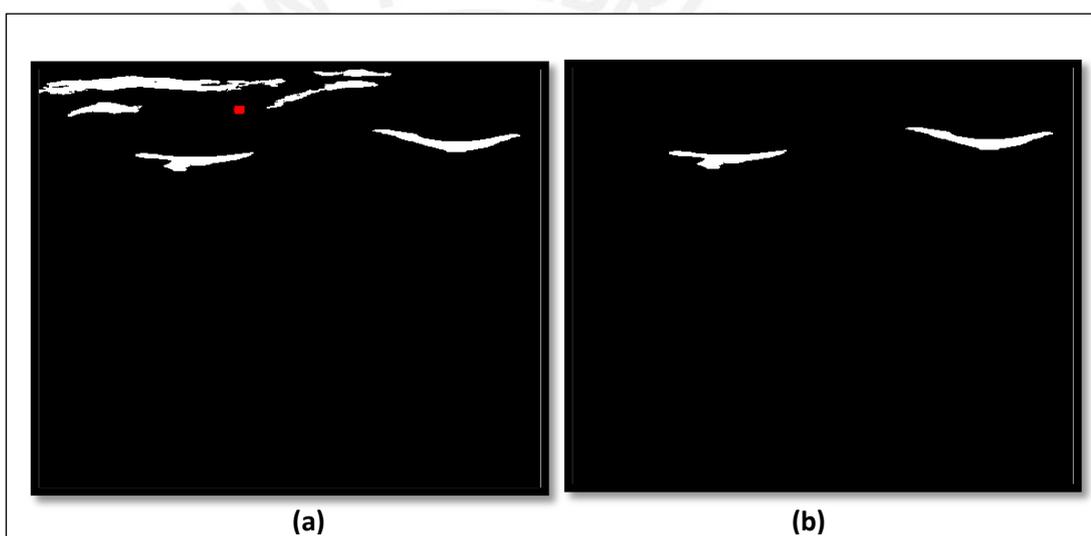


Figura 3.7. (a) El punto rojo indica el centro de masa de la imagen. (b) Regiones consideradas para el análisis por encontrarse debajo del centro de masa.

d) Operación morfológica de apertura de cada cuadro de video

Para este caso se trabajó con un elemento estructural 'disco' de 4 píxeles de radio. Esta operación se utiliza para abrir pequeños huecos. En el caso del presente trabajo, es necesario eliminar las áreas pequeñas mediante su desintegración, permitiendo que queden las áreas más grandes, por ser las de interés.

e) Operación OR entre todos los cuadros de videos.

Luego de haber obtenido la ubicación de las zonas que conforman la pleura en cada cuadro de video, se procederá a obtener una máscara total donde se superpongan todas las regiones consideradas como lugar geométrico de la pleura. Esto es debido a que durante el video, la pleura

cambia ligeramente de posición, oscilando arriba y abajo a causa del proceso de deslizamiento pulmonar (definida en **sección 2.3.3**).

Ver **Figura 3.8**.

2. Aproximación de los puntos que conforman la pleura con interpolación spline cúbica (Segunda parte)

La imagen binaria con las posiciones de la pleura para cada cuadro de video (ver **Figura 3.7 b**), será el dato de entrada para esta segunda parte de la segmentación de la pleura.

En el diagrama de bloques presentado en la **Figura 3.9** se detallan dos procesos en paralelo que resultaron de realizar la detección de la pleura. Por un lado se tiene el procedimiento de aproximación de la línea pleural, específicamente de la parietal (capa más externa de la pleura), y por el otro, se tiene la segmentación de los espacios intercostales, que son finalmente la región de interés para el análisis de la presente tesis.



Figura 3.8. Resultado de la operación OR entre todos los cuadros del video al que pertenecen. Se muestra el lugar geométrico de la línea pleural, es decir las posiciones superpuestas de su ubicación a lo largo de todo el video.

a) Obtención de las regiones de interés que conforman la pleura en cada cuadro de video

En el inciso **c) de la parte 1) de 3.2.2** se habló sobre utilizar únicamente aquellas áreas que se encontraban debajo del centro de masa de la imagen. Cada uno de los cuadros que se obtienen de realizar la discriminación por posición del centroide, se multiplicará con la máscara final para obtener las áreas que conforman el espacio pleural (ver **Figura**

3.10). Esto debido a que algunas áreas fuera del lugar geométrico pueden filtrarse.

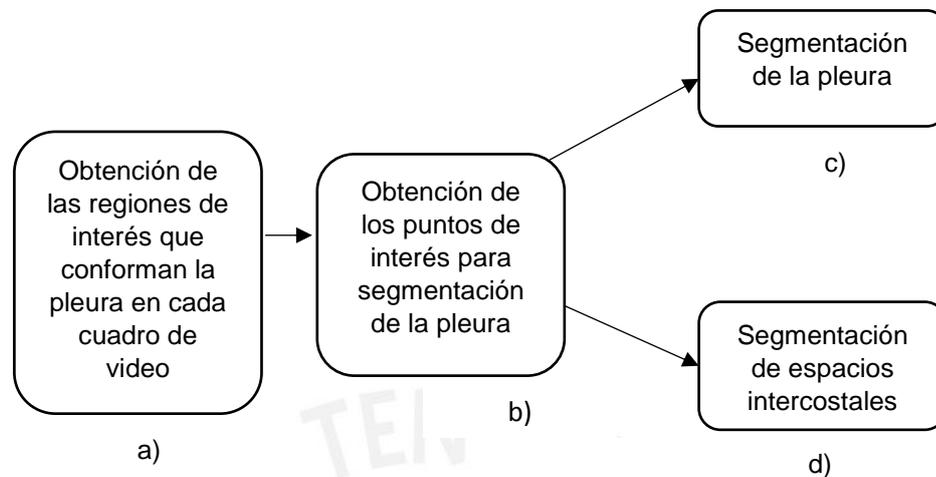


Figura 3.9. Diagrama de bloques de la segmentación de la línea pleural y los espacios intercostales. Elaboración propia.

b) Obtención de los puntos de interés para la segmentación de la pleura.

Las regiones de la **Figura 3.10 c)** constituyen la pleura. Sin embargo, lo que se busca segmentar es solo la línea parietal (capa superior) para poder realizar un “barrido” hacia abajo y quedarnos solo con las zonas intercostales. Para esto, se buscarán los valores de ‘1’ en cada inicio de columna (cabe recordar la naturaleza binaria de estas imágenes) y el resto de ella se completará con ‘0’, así como se muestra en la **Figura 3.11**.

c) Segmentación de la pleura.

A partir de los puntos de interés obtenidos, se procede a segmentar la línea pleural mediante una interpolación spline cúbica. Ver **Figura 3.12**.

En la **Figura 3.13** se muestra la comparación entre la línea pleural calculada mediante spline y la línea pleural real.

La segmentación de la línea pleural es un procedimiento importante del cual depende la ubicación de los espacios intercostales, los cuales se desprenden a partir de ella, hacia debajo de la imagen. El error calculado en este procedimiento se mostrará en el capítulo 4 de Resultados.

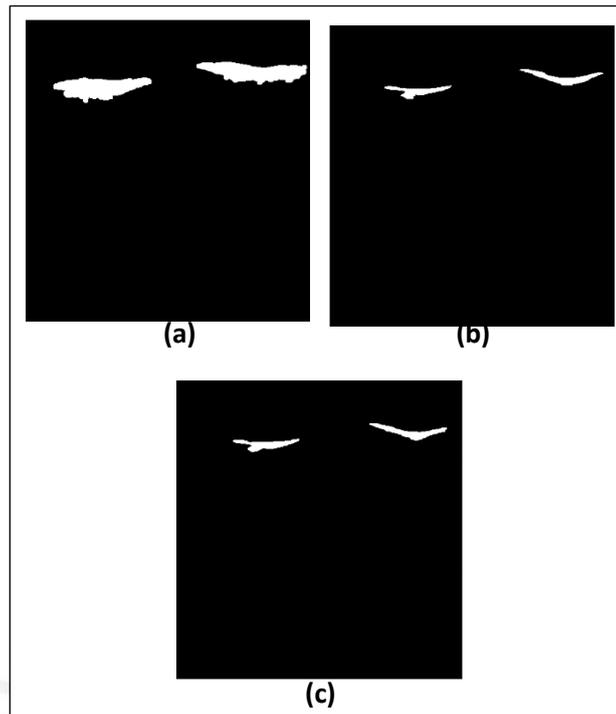


Figura 3.10. La imagen (a) corresponde a la máscara final, y la imagen (b) corresponde a las zonas consideradas debajo del centroide de la imagen. Ambas son multiplicadas y se obtiene (c) que es la imagen con las regiones correctas correspondientes a la pleura.

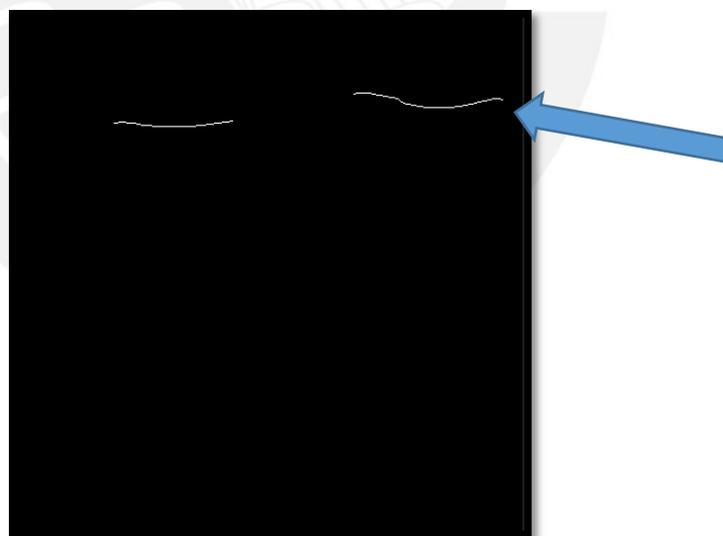


Figura 3.11. La flecha azul indica los puntos de interés para la aproximación de toda la línea pleural.

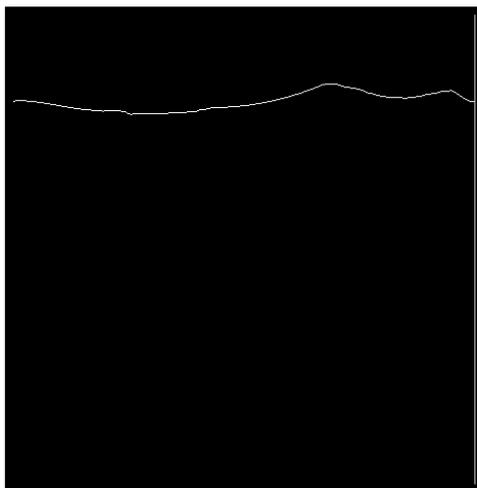


Figura 3.12. Aproximación de la línea pleural utilizando interpolación cúbica.

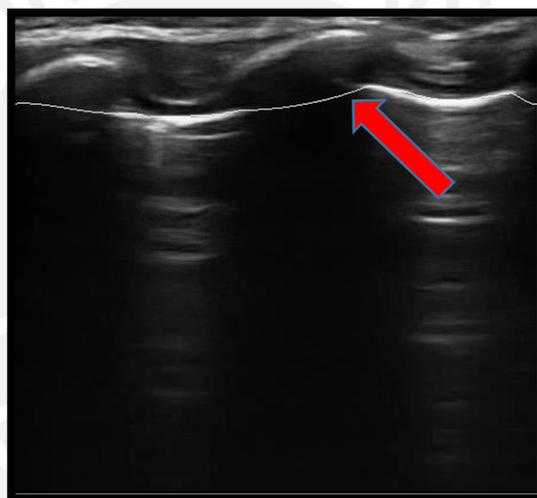


Figura 3.13. Comparación entre la posición de la línea pleural segmentada (línea blanca continua señalada con la flecha roja) y la posición real de la línea pleural.

3.2.3 Detección automática de los espacios intercostales (regiones de interés) (C)

Si bien es cierto, el paso inicial era encontrar la línea pleural dentro de la imagen para partir de ahí y segmentar los espacios intercostales, no se necesitará la línea pleural completa, ya que los espacios intercostales están separados por los vacíos negros generados por la presencia de las costillas, las cuales impiden la propagación de las ondas ultrasónicas generando unas sombras en la imagen. No obstante, la segmentación de la línea en su totalidad sí es de importancia debido a que la caracterización del espacio pleural representa una técnica útil para el diagnóstico de algunas patologías, entre las que destaca, la efusión pleural [37].

Para este estudio en particular, bastará con tomar la línea pleural dividida, así como se muestra en la **Figura 3.14**.

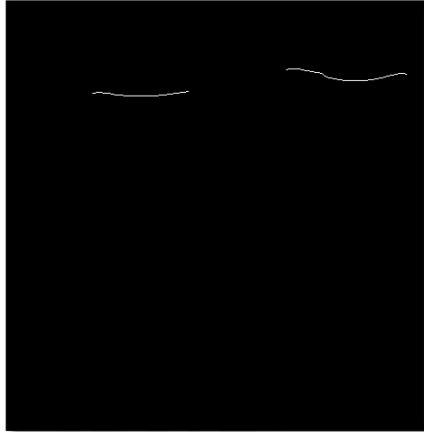


Figura 3.14. Segmentación de los puntos pertenecientes a la pleura, ubicados en los espacios intercostales.

En la **Figura 3.14** se muestran los puntos iniciales de las zonas intercostales. En este caso, ya no se completará la columna con '0', si no con '1' de manera que a partir de los puntos hacia abajo se tomen los píxeles como información. De esa manera, se multiplicará la imagen obtenida con la imagen de ultrasonido real sin alteraciones. Ver **Figura 3.15**.

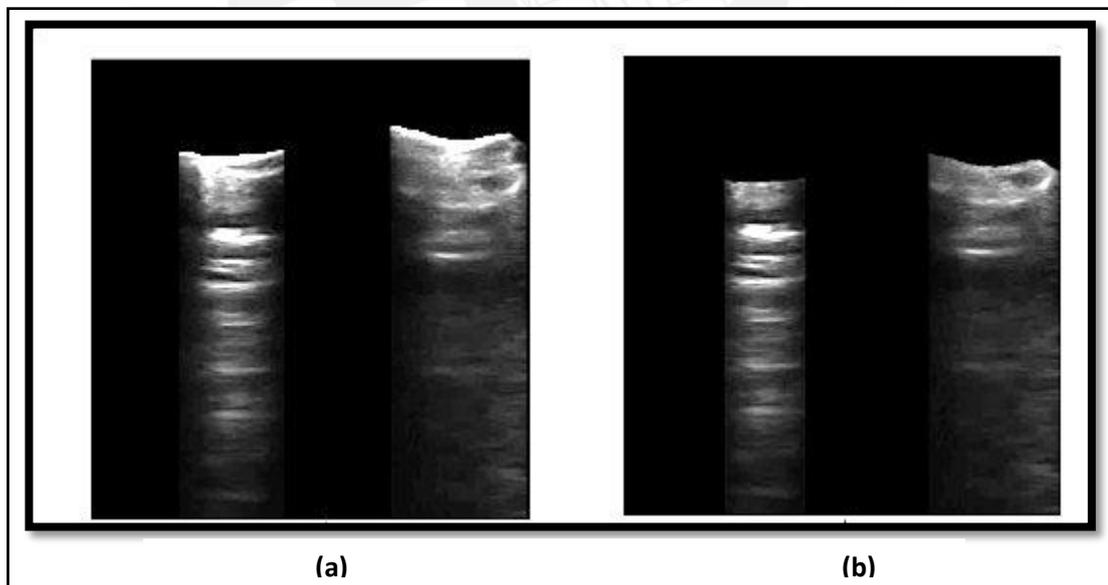


Figura 3.15. (a) Imagen obtenida de multiplicar la imagen original de ultrasonido con la máscara de '1's tomados a partir de la línea pleural. (b) Línea pleural descendida 30 píxeles para evitar la zona de la pleura y solamente analizar el espacio intercostal.

Para un mejor análisis de las regiones de interés, estos puntos descenderán 30 píxeles en la imagen, ya que, de no ser así, se estaría tomando a la pleura como parte del análisis y por ser una zona de mucho brillo interferirá en la interpretación de los datos. Como se muestra en la **Figura 3.15b)**

3.2.4 Análisis de los espacios intercostales (D)

Con los espacios intercostales ya segmentados, ahora se procederá a explicar el algoritmo empleado para analizar la presencia de líneas B. En el siguiente punto se explicará a detalle el procedimiento.

3.3 Extracción de las características de los histogramas de cada espacio intercostal

Primero deberán clasificarse los espacios intercostales (como sanos o enfermos).

3.3.1 Creación de una matriz de antecedentes

Llamaremos matriz de antecedentes o matriz de *Ground Truth* (matriz GT) a aquella matriz lógica (formada por '1's y '0's) que se generará por cada cuadro de video en donde los grupos de '1's representan los lugares con línea B y los '0's representan a los espacios sanos. Ver **Figura 3.16.**

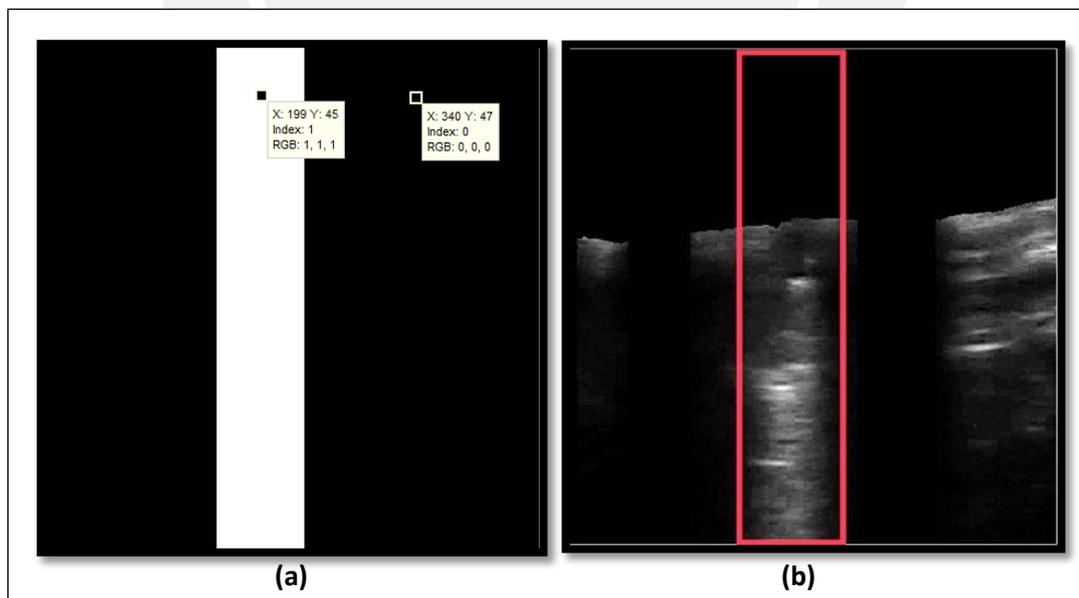


Figura 3.16. (a) Matriz GT conformada de '1's y '0's correspondientes a la presencia o no presencia de línea B. (b) Cuadro de video del cual se desprende la matriz GT en (a). En el rectángulo rojo se observa la ubicación de la línea B.

La utilidad de obtener esta matriz es la de identificar los espacios intercostales sanos y enfermos, para poder apreciar la correlación que se genera entre las características matemáticas a estudiar (energía, curtosis, oblicuidad, desviación estándar y promedio).

Para estimar los valores claves que permitirán dicha separación, se utilizarán 3 métodos: Análisis por Curva ROC, Análisis por máquina de vector de soporte (Support Vector Machine) y Análisis de componentes principales (Principal Component Analysis) siendo estos dos últimos ampliamente usado en Aprendizaje Automático (más conocido como *machine learning*, por su nombre en inglés) [39].

Dichos métodos se explicarán más adelante.

3.3.2 Valores cuantitativos de espacios intercostales sanos y enfermos

Previamente se explicó a detalle cómo se obtuvieron los espacios intercostales, que son las zonas a analizar. En la **Figura 3.15b** se observa el resultado. A dicha imagen le llamaremos EIC (Espacio Intercostal) para una mejor explicación en los pasos siguientes.

A continuación, se presenta el diagrama de bloques (ver **Figura 3.17**) de la extracción de características de los histogramas de todos los EIC, junto con la descripción gráfica de la parte a) y d) (ver **Figura 3.18**).

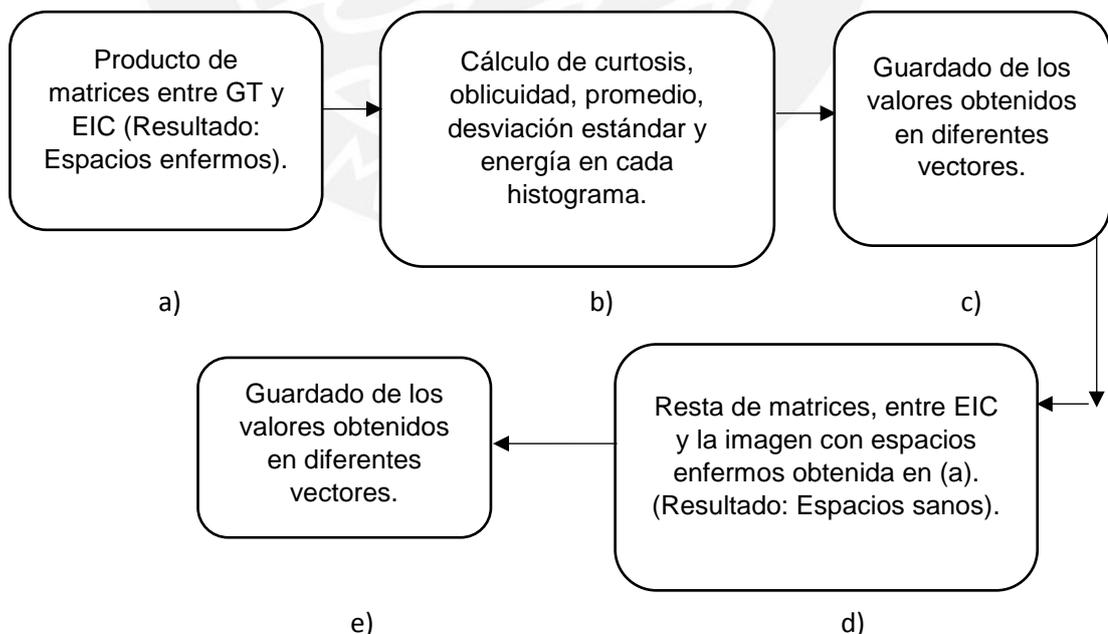


Figura 3.17. Diagrama de bloques para la extracción de características del histograma.

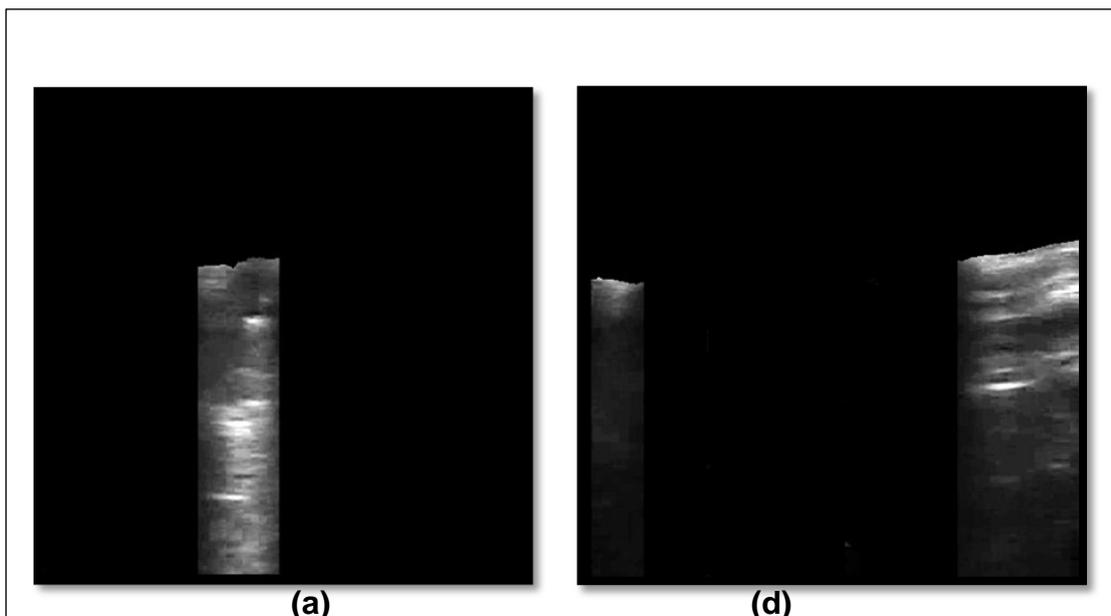


Figura 3.18. Descripción gráfica de la parte (a) y (d) del diagrama de bloques.

Una vez separados los espacios intercostales entre enfermos y sanos, procedemos a extraer las características matemáticas de cada uno, con la finalidad de apreciar las diferencias entre ambos y enseñarle al algoritmo a diferenciarlos. Por cada espacio intercostal se calculó 5 características matemáticas: desviación estándar, energía, curtosis, oblicuidad y promedio, que fueron agrupados de acuerdo al análisis que se realizó, los cuales se explican en el punto siguiente.

Los resultados de un conjunto de entrenamiento (29 videos) se muestran en la **Tabla 3.1**:

Tabla 3.1. Conjunto de entrenamiento del algoritmo.

Cantidad de espacios intercostales sanos	Cantidad de espacios intercostales enfermos	TOTAL de espacios intercostales	Cantidad de datos analizados (total de espacios intercostales multiplicado con el total de características que se analizan)
1643	13274	14917	74585

3.3.3 Métodos para el análisis de los vectores de datos

Con los datos obtenidos (energía, curtosis, desviación estándar, promedio y oblicuidad) de los espacios intercostales sanos y enfermos del apartado anterior, procedemos a evaluarlos mediante curva ROC, máquina de vector de soporte y componentes principales para encontrar un clasificador de espacios sanos y enfermos automático.

3.3.3.1 Análisis con Curva ROC

El punto clave para el análisis con curva ROC, surge a partir de encontrar un valor umbral (definido en **sección 2.4.3.3**) para cada característica matemática analizada (desviación estándar, energía, curtosis, oblicuidad y promedio en este caso) que va a permitir afirmar: “Los valores mayores a este umbral son considerados como espacios intercostales enfermos y los valores menores, sanos” o viceversa.

Para encontrar dicho umbral se realizaron pruebas en el conjunto de entrenamiento detalladas a continuación.

Procedimiento de análisis:

a) Los valores con los que se cuentan son de 2 tipos: para espacios intercostales sanos y para espacios intercostales enfermos. Es decir, se tiene 10 vectores de datos:

Espacios intercostales enfermos	}	Datos de desviación estándar.
		Datos de energía.
		Datos de curtosis.
		Datos de oblicuidad.
		Datos de promedio.
Espacios intercostales sanos	}	Datos de desviación estándar.
		Datos de energía.
		Datos de curtosis.
		Datos de oblicuidad.
		Datos de promedio.

Como lo que se busca es encontrar un valor umbral por cada característica matemática que permita clasificar entre espacio sano y enfermo, se formarán nuevos vectores tal como se muestra a continuación:

$desviación\ estándar = [desviación\ estándar\ enfermos \quad desviación\ estándar\ sanos]$
 $energía = [energía\ enfermos \quad energía\ sanos]$
 $kurtosis = [kurtosis\ enfermos \quad kurtosis\ sanos]$
 $oblicuidad = [oblicuidad\ enfermos \quad oblicuidad\ sanos]$
 $promedio = [promedio\ enfermos \quad promedio\ sanos]$

- a) Ahora se creará un vector de antecedentes (o *Ground Truth*), vector GT, para cada característica matemática, de manera que se pueda discernir qué valores de desviación estándar, energía, curtosis, etc son de espacios sanos y cuáles de enfermos. En este caso, se vuelve a considerar '1' como enfermo y '0' como sano, igual que en la **sección 3.3.2**
- b) A continuación, se calculan los valores: Verdaderos Positivos (VP), Verdaderos Negativos (VN), Falsos Positivos (FP), Falsos Negativos (FN) para hallar la sensibilidad, especificidad y exactitud en cada característica matemática. Los datos fueron sometidos a pruebas con varios umbrales para encontrar el más óptimo, generando las curvas ROC, cuyas gráficas serán mostradas en el capítulo 4 de Resultados.

3.3.3.2 Aprendizaje automático: Análisis con máquina de vector de soporte (*Support Vector Machine*)

Un modelo predictivo es el proceso por el que un modelo es creado para predecir un resultado, basándose en el comportamiento que tienen los agentes involucrados en un estudio previo. Cuando este resultado es una categoría (sano o enfermo, por ejemplo) se le denomina clasificación, y si el resultado es un número se llamará regresión. La idea básica para un modelo predictivo es asociar las características extraídas de los objetos en estudio de acuerdo a su similitud, para finalmente asociarlos a reglas que puedan ser útiles en las observaciones de nuevos datos. El modelo predictivo ha sido usado ampliamente en aprendizaje automático como una manera de entrenar a un algoritmo y poder “predecir el futuro” a partir de ello [38].

Los datos obtenidos previamente serán analizados mediante “Máquina de vector de soporte”, que constituye precisamente un ejemplo de modelo predictivo, ya que a partir del entrenamiento de un subconjunto de la base de datos que se está estudiando, se buscará una similitud entre las clases

presentes (sano y enfermo) de manera que se genere un clasificador que podrá determinar a qué categoría pertenece un nuevo dato de entrada, en este caso, un video de ultrasonido de tórax de un paciente.

Anteriormente se evaluó cada característica por separado para diferenciar entre espacios intercostales sanos y enfermos. Ahora, con este segundo análisis, se evaluarán dos características en simultáneo para poder discernir entre sano y enfermo. Los pares combinados para el siguiente procedimiento, serán: *desviación estándar-energía*, *desviación estándar-curtosis*, *desviación estándar-oblicuidad*, *desviación estándar-promedio*, *energía-curtosis*, *energía-oblicuidad*, *energía-promedio*, *curtosis-oblicuidad*, *curtosis-promedio* y *oblicuidad-promedio*.

Como se mostró en la **parte a) de la sección 3.3.3.1**, se cuenta con 10 vectores de datos y se acondicionarán como sigue:

- a) Se formarán nuevos vectores por cada característica y en cada vector se concatenarán los valores de sanos y enfermos. Para el final de esta parte se tienen 5 vectores: desviación estándar, energía, promedio, curtosis y oblicuidad, cada uno con valores de sanos y enfermos.
- b) Finalmente, se creará 1 vector de antecedentes (vector GT) que servirá como referencia para la clasificación de los dos tipos de datos (sanos y enfermos).

Las gráficas que se obtendrán en esta parte corresponden a la distribución que los datos adoptan ante 2 características, en simultáneo; y para poder realizar la separación de clases, se creará el mejor hiperplano (**sección 2.4.3.6**) que permita diferenciar a sanos y enfermos mediante el comando *svmtrain* de Matlab, que es el comando que se encargará del entrenamiento del clasificador, a partir de la data que se proporciona.

3.3.3.3 Aprendizaje automático: Análisis de componentes principales con máquina de vector de soporte.

El procedimiento para análisis es el mismo que en la **sección 3.3.3.2**, salvo que esta vez no se analizarán las características de dos en dos, si no, que se tomarán las 5 en simultáneo y se generarán las componentes principales, de las cuales extraeremos las 2 primeras por ser las más importantes (análisis bidimensional).

Las gráficas que se obtendrán en esta parte corresponden a la distribución que los datos adoptan ante las 2 componentes principales; y para generarlas se usará el comando *pca* de Matlab.

3.4 Diagrama de bloques del algoritmo

A continuación, se muestra en la **Figura 3.19** el diagrama de bloques del algoritmo desarrollado.

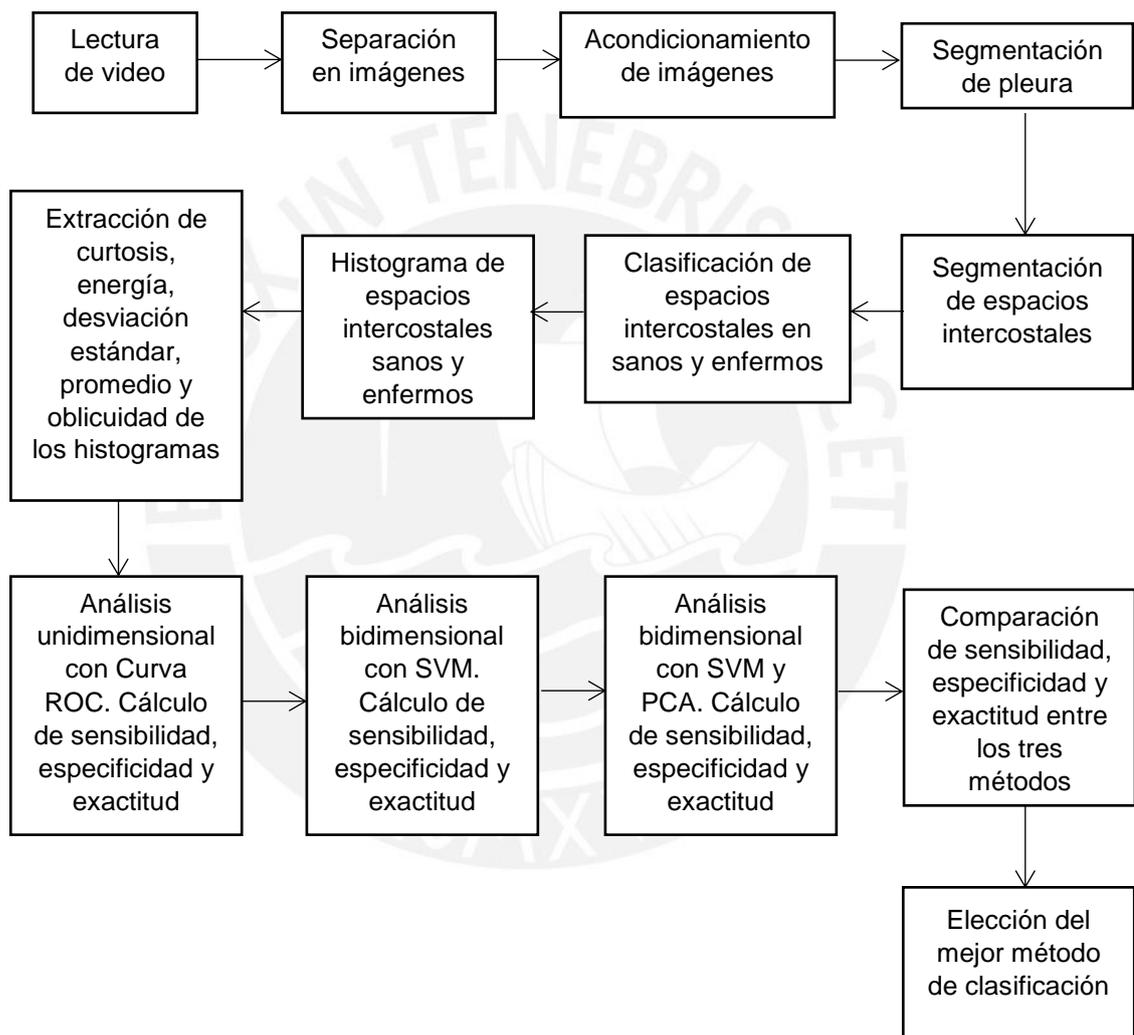


Figura 3.19. Diagrama de bloques del algoritmo de clasificación de espacios intercostales.

CAPÍTULO 4: Resultados, análisis y discusión.

En este último capítulo se presentarán los resultados de los algoritmos, junto con el análisis y una discusión de dichos resultados.

4.1 Resultados de la segmentación de pleura

Como se recuerda, la primera parte del algoritmo corresponde a la detección de la línea pleural para obtener a partir de ahí, los espacios intercostales, que vienen a ser las zonas de interés.

Con la finalidad de calcular el error en este procedimiento, los resultados obtenidos fueron comparados con la selección manual de la pleura, es decir, la selección de puntos en cada cuadro de video de la locación de la línea pleural. Dichos puntos fueron aproximados también usando interpolación cúbica. La selección de los puntos fue sobre la pleura parietal, como se muestra en la **Figura 4.1.**, los cuales descenderán 30 píxeles, tal cual se hizo con los puntos obtenidos por el algoritmo de detección pleural en la **sección 3.2.2.**

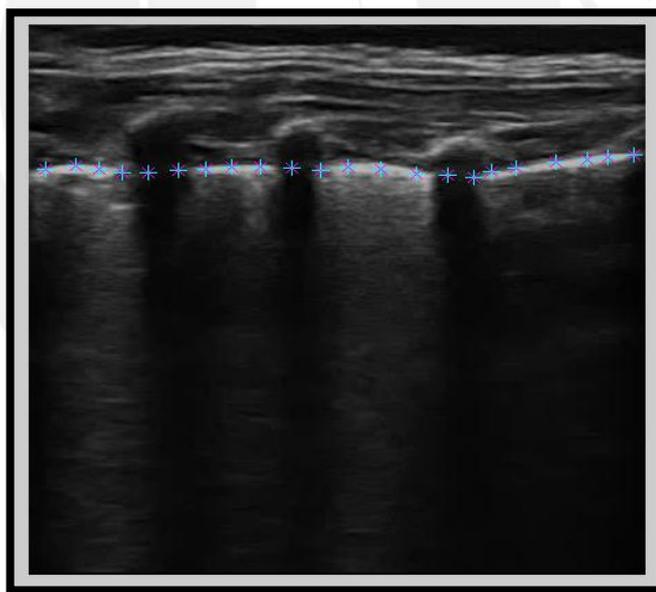


Figura 4.1. Selección manual de la pleura parietal. Base para la comparación con el resultado del algoritmo.

Para el cálculo del error se restó la aproximación obtenida manualmente con la aproximación obtenida por el algoritmo en cada video, es decir, pixel a pixel. Estos valores se promediaron para obtener el error por cuadro. Finalmente, los errores por cuadro se promediaron también y se obtuvo el

error por video. A continuación, se muestra la **Tabla 4.1** con los errores en cada video de la base de datos empleada.

Tabla 4.1. Cálculo del valor absoluto del error promedio en cada video de la base de datos usada.

Número de video	Valor absoluto del error promedio (pixeles)	Número de video	Valor absoluto del error promedio (pixeles)
1	2.53	16	5.43
2	0.97	17	2.17
3	3.38	18	4.21
4	1	19	2.5
5	1.89	20	7.43
6	6.28	21	5.6
7	10.19	22	4.76
8	4.9	23	3.27
9	8.82	24	6.62
10	6.62	25	0.41
11	9.37	26	9.73
12	3.84	27	2.1
13	0.55	28	3.28
14	17.38	29	5.75
15	6.39	30	5.8
Error promedio (pixeles): 5.1			

4.2 Resultados del Análisis por Curva ROC

Como se mencionó en la **parte c) de la sección 3.3.3.1**, se calculó especificidad, sensibilidad y exactitud para cada umbral de prueba en cada característica matemática: energía, desviación estándar, curtosis, promedio y oblicuidad. En la **Figura 4.2** se muestran las 5 curvas ROC calculadas y el umbral más óptimo para la clasificación de los espacios intercostales en el conjunto de entrenamiento.

En la **gráfica 4.2** se observan las 5 curvas ROC obtenidas del análisis de varios umbrales para cada una de ellas.

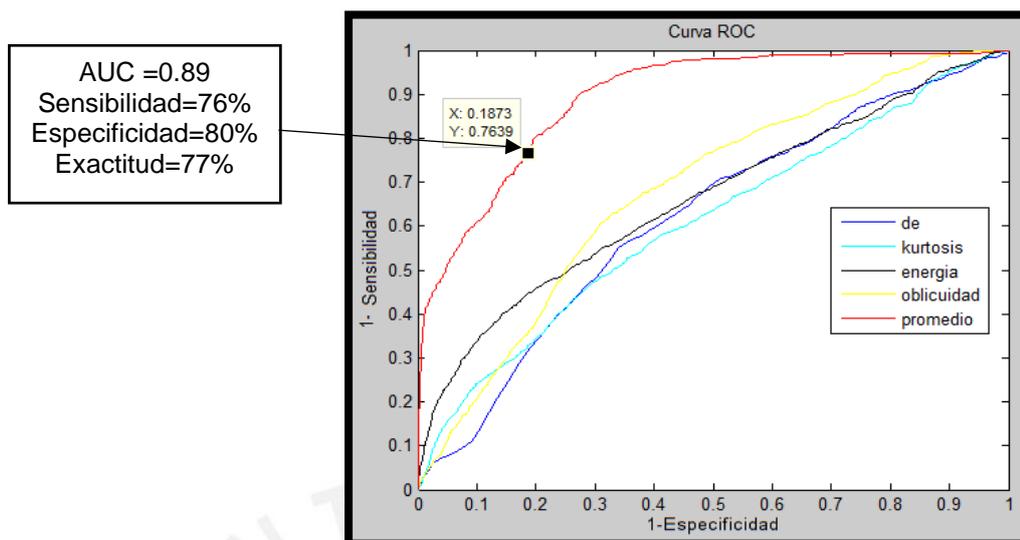


Figura 4.2. Curva ROC de energía, curtosis, oblicuidad, promedio y desviación estándar (de). El umbral óptimo ocurre para un valor de “promedio” de 15 con sensibilidad de 76%, especificidad de 80% y exactitud de 77% en el conjunto de entrenamiento.

En la **tabla 4.2** se muestran los resultados de área bajo la curva para cada una de las características matemáticas.

Tabla 4.2. Resultados de áreas bajo la curva para cada característica estudiada.

Característica	AUC
Promedio	0.89
Curtosis	0.72
Desv. estándar	0.73
Oblicuidad	0.79
Energía	0.76

De acuerdo a la definición de curva ROC en la **Sección 2.5.2.4**, la curva de mayor utilidad (por tener el mayor valor de AUC) para el presente análisis será la de promedio, considerando como umbral a 15. Esto quiere decir que aquellos espacios intercostales que tengan un promedio mayor a 15 se considerarán enfermos, y los que tengan un valor menor, serán sanos.

Se probó el algoritmo en todos los espacios intercostales en los conjuntos de prueba y el promedio arrojó los siguientes resultados en la **Tabla 4.3**.

Tabla 4.3 Resultados obtenidos mediante análisis por Curva ROC en el conjunto de prueba.

Sensibilidad	Especificidad	Exactitud
77%	75%	75%

4.3 Resultados con el uso de máquina de vector de soporte

Se analizaron los conjuntos de entrenamiento usando kernel lineal, polinomial y rbf, siendo el kernel rbf el que permitió obtener la mejor clasificación.

La elección de C y sigma para dicho kernel, se realizó mediante análisis exploratorio en un conjunto amplio de datos. Para C, se realizaron iteraciones desde 0 hasta 10 con un incremento ascendente de 0.1. Para el caso de sigma, se realizaron iteraciones desde 0 hasta 1 con un incremento ascendente de 0.01. Se realizó la prueba con números mayores, pero el algoritmo no funcionaba para dichas cantidades. En la **Figura 4.3** se muestran C, sigma y el porcentaje de sensibilidad de acuerdo a su dimensión.

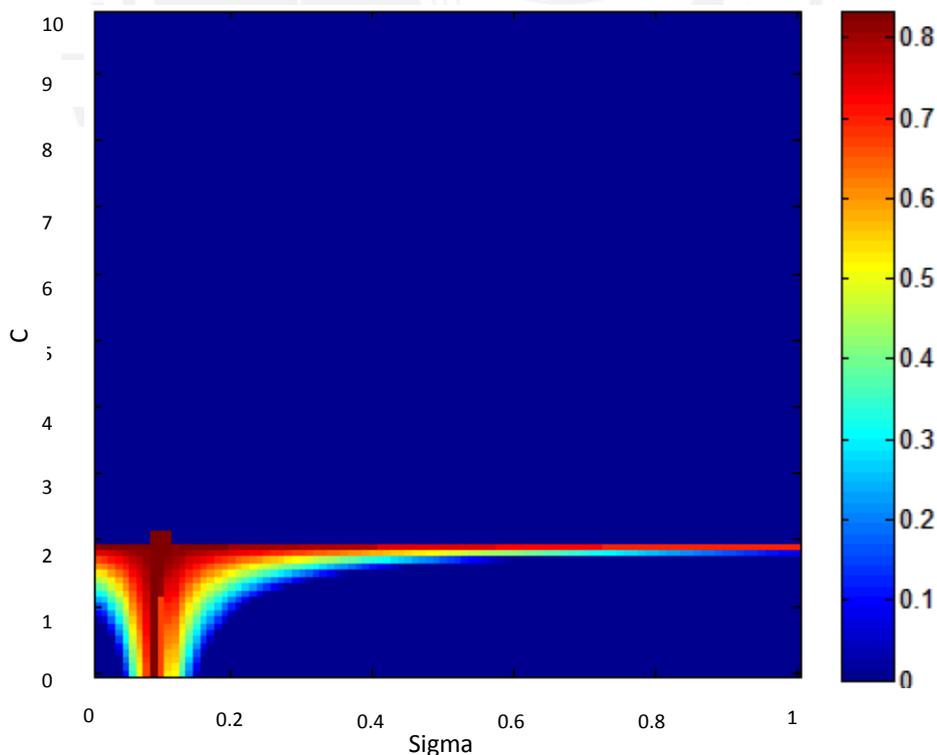


Figura 4.3. Gráfica de sensibilidad respecto a C y sigma. Se aprecia que la mayor sensibilidad se obtiene para un valor aproximado de C=2.1 y sigma=0.1. La parte azul corresponde a los valores para los cuales el algoritmo mostró error al no poder calcular un clasificador para los datos evaluados.

En la **Figura 4. 4** se muestran C, sigma y el porcentaje de especificidad de acuerdo a su dimensión.

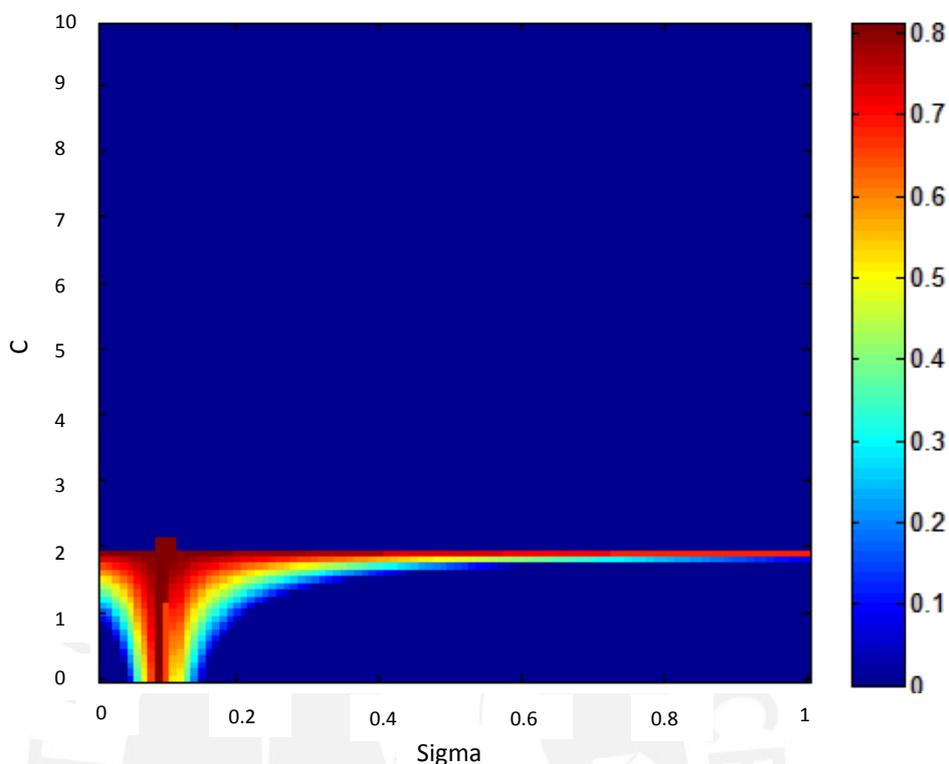


Figura 4. 4. Gráfica de especificidad respecto a C y sigma. Se aprecia que la mayor especificidad se obtiene para un valor aproximado de C=2.1 y sigma=0.1. La parte azul corresponde a los valores para los cuales el algoritmo mostró error al no poder calcular un clasificador para los datos evaluados.

En la **Tabla 4.4** se muestran, a modo de resumen, los resultados con kernel rbf para cada par de características.

Tabla 4. 4. Resultados obtenidos mediante análisis por SVM con kernel rbf en el conjunto de entrenamiento, indicando la sensibilidad, especificidad y exactitud.

Características	C	Sigma	Sensibilidad (%)	Especificidad (%)	Exactitud (%)
Energía vs Desv. Estándar	1.1±0.1	0.1±0.1	74±5	75±3	75±4
Kurtosis vs Desv. Estándar	1.1±0.1	0.1±0.1	74±4	70±3	75±6
Oblicuidad vs Desv. Estándar	2.1±0.1	0.1±0.1	77±3	81±2	82±5
Promedio vs Desv. Estándar	2.1±0.1	0.1±0.1	82±5	77±4	80±2
Kurtosis vs Energía	2.1±0.1	0.1±0.1	69±4	64±2	70±2

Oblicuidad vs Energía	2.1±0.1	0.1±0.1	73±3	76±2	76±2
Promedio vs Energía	0.2±0.1	0.01±0.01	82±3	80±1	79±2
Oblicuidad vs Kurtosis	0.06±0.01	0.1±0.1	60±5	79±2	70±1
Promedio vs Kurtosis	1.6±0.1	0.1±0.1	79±2	89±1	85±2
Promedio vs Oblicuidad	2.1±0.1	0.1±0.1	84±3	80±4	83±3

Los mejores resultados, se obtuvieron con el par Promedio-Oblicuidad, usando kernel rbf con: parámetro C= 2.1 y sigma= 0.1 (**sección 2.4.3.6**). La sensibilidad, especificidad y exactitud fueron de 84%, 81% y 83% en el conjunto de entrenamiento. Ver **Figura 4.5** y **Figura 4.6**.

El algoritmo arrojó los siguientes resultados para el conjunto de prueba. Ver **Tabla 4.5**.

Tabla 4.5. Resultados obtenidos mediante análisis por SVM con rbf, en el par Promedio vs Oblicuidad, en el conjunto de prueba.

Sensibilidad	Especificidad	Exactitud
93%	86%	88%

4.4 Resultados con el uso de Análisis de componentes principales y máquina de vector de soporte.

Las 5 variables en estudio fueron procesadas por PCA con la finalidad de obtener 2 componentes principales (2 nuevas variables basadas en las originales). Se decide usar las dos primeras debido a que tienen la mayor significancia respecto a las otras. La **Figura 4. 7** muestra la varianza de las tres primeras componentes y su porcentaje respecto a la influencia que tienen en el conjunto de entrenamiento.

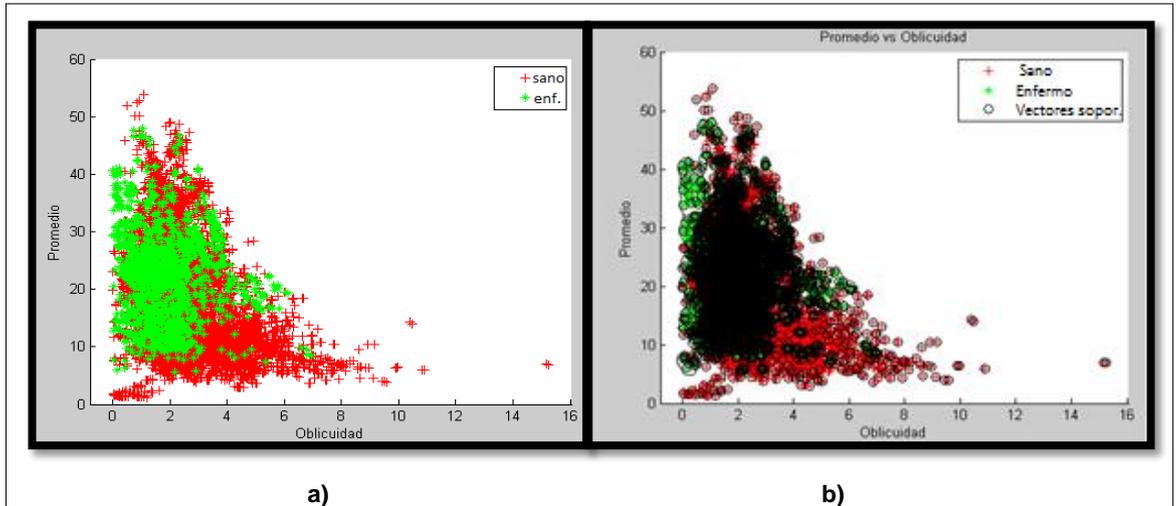


Figura 4.5. a) Conjunto de entrenamiento, dejando el primer video para conjunto de prueba. b) Clasificación de espacios intercostales sanos y enfermos comparando promedio y oblicuidad. Debido a que C es pequeño, el número de vectores soporte es alto, así mismo, un sigma menor significa un hiperplano bastante curvo que rodea y se adapta a la forma del grupo de espacios enfermos.

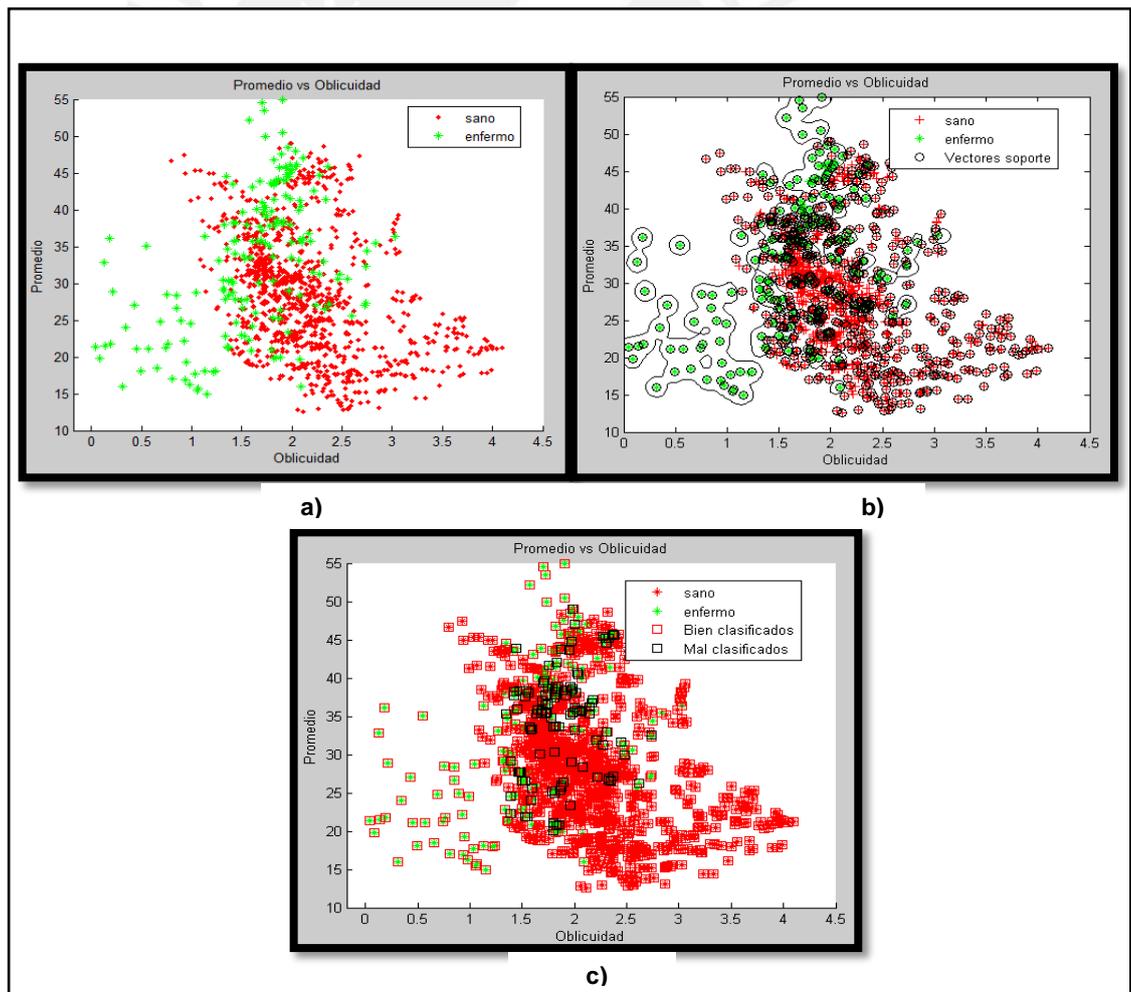


Figura 4.6. a) Conjunto de prueba (video no considerado en el entrenamiento) que muestra la distribución de los espacios intercostales. b) Clasificación de

espacios intercostales con los parámetros rbf definidos en el conjunto de entrenamiento. c) Gráfico que muestra los espacios correctamente clasificados y mal clasificados.

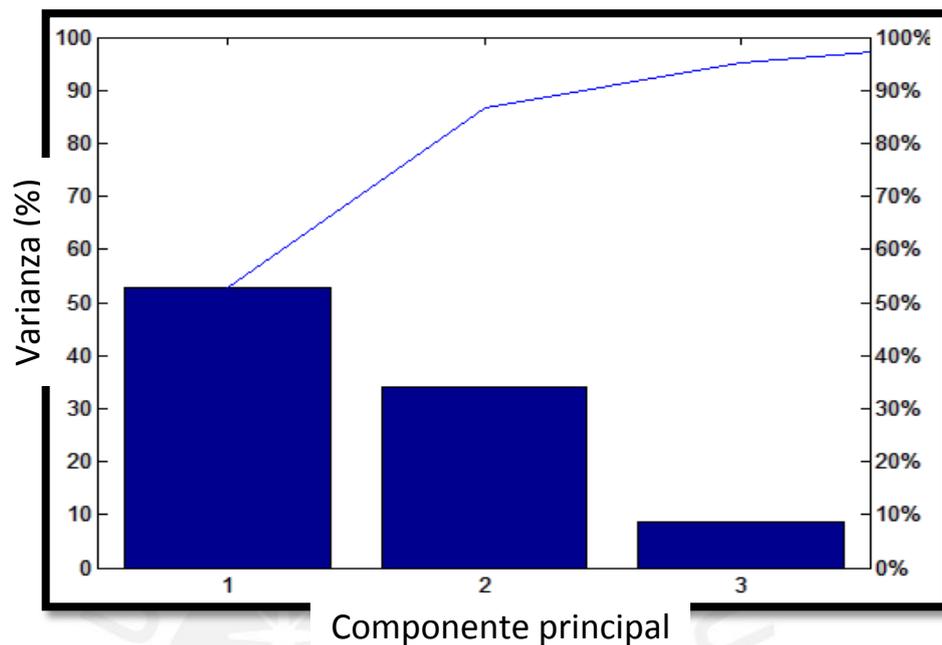


Figura 4.7. Varianza correspondiente a cada componente principal. Se aprecia que las dos primeras son las más representativas, y por lo tanto es con las cuales se trabajará, ya que juntas alcanzan casi el 90% de varianza de los datos de entrenamiento.

A continuación, se muestran en la **Figura 4.8** las dos nuevas componentes obtenidas y la influencia de cada variable original (coeficientes) en la obtención de las mismas.

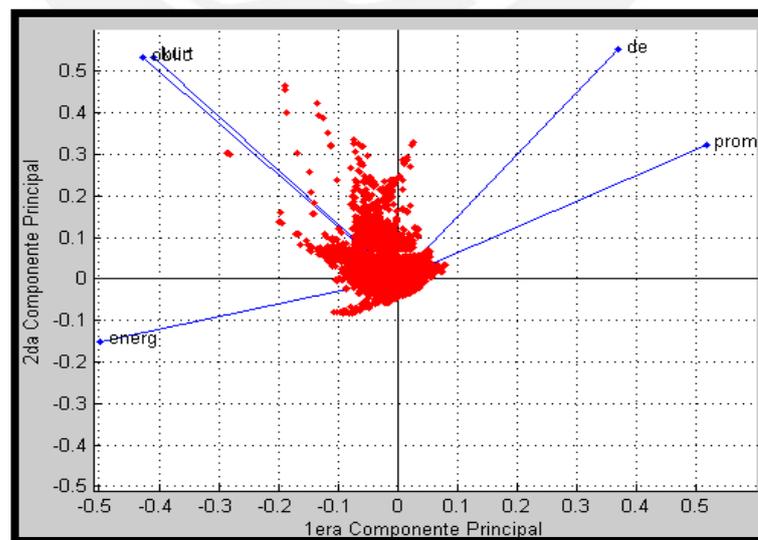


Figura 4.8. Los puntos rojos representan la distribución de datos de un conjunto de entrenamiento y los vectores azules, la importancia de las variables originales en las

dos primeras componentes, donde de=desviación estándar, prom=promedio, energ=energía, obli=oblicuidad y kurt=kurtosis. Debido a la cercanía de valores, el texto de “oblicuidad” y “kurtosis” no logra distinguirse bien.

En la **Figura 4. 9** se muestran los coeficientes (pesos) que cada variable original aporta a las nuevas componentes.

Coeficientes de componentes principales					
	1	2	3	4	5
1	0.3688	0.5518	-0.3792	-0.5411	0.3505
2	-0.4984	-0.1508	-0.8481	0.0974	-0.0052
3	-0.4094	0.5343	0.1967	0.4734	0.5330
4	-0.4258	0.5321	0.1287	-0.2704	-0.6678
5	0.5164	0.3226	-0.2858	0.6329	-0.3835

Figura 4. 9. Coeficientes que aportan las variables originales a las nuevas componentes. Las columnas representan las 5 nuevas componentes principales y las filas, las variables originales (del 1 al 5: desviación estándar, energía, kurtosis, oblicuidad y promedio).

Se analizaron los conjuntos de entrenamiento usando kernel lineal y rbf, siendo el kernel lineal el que permitió obtener la mejor clasificación.

La elección de C para dicho kernel, se realizó mediante análisis exploratorio en un conjunto amplio de datos. Para C, se realizaron iteraciones desde 0 hasta 2 con un incremento ascendente de 0.1. Se realizó la prueba con números mayores, pero el algoritmo no funcionaba para dichas cantidades. En la **Figura 4.10** se muestran C y el porcentaje de sensibilidad de acuerdo a su dimensión.

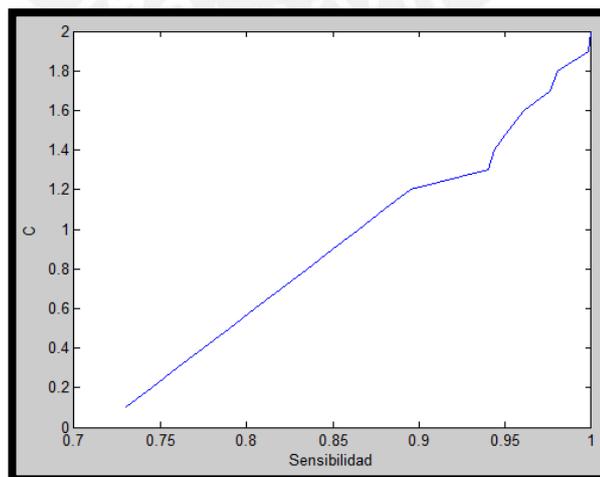


Figura 4. 10. Gráfica de sensibilidad respecto al valor de C para un análisis con kernel lineal.

En la **Figura 4.11** se muestran C y el porcentaje de especificidad de acuerdo a su dimensión.

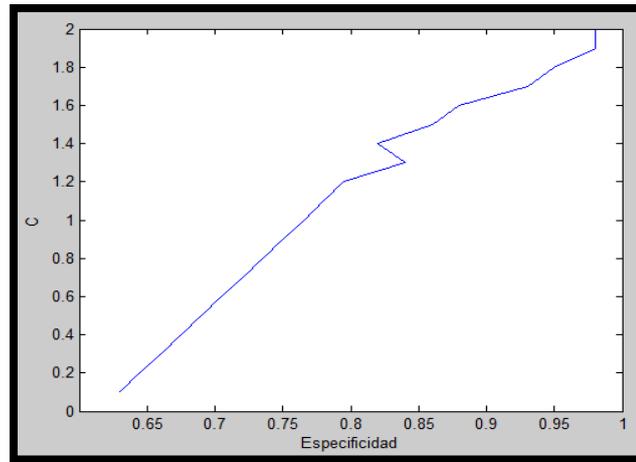


Figura 4. 11. Gráfica de especificidad respecto al valor de C para un análisis con kernel lineal.

El parámetro que permitió obtener la mejor performance fue $C=2$, con kernel lineal. Los resultados del conjunto de entrenamiento arrojaron una sensibilidad, especificidad y exactitud de 100%, 99% y 98% respectivamente. La **Figura 4.12** muestra los resultados gráficos del conjunto de entrenamiento.

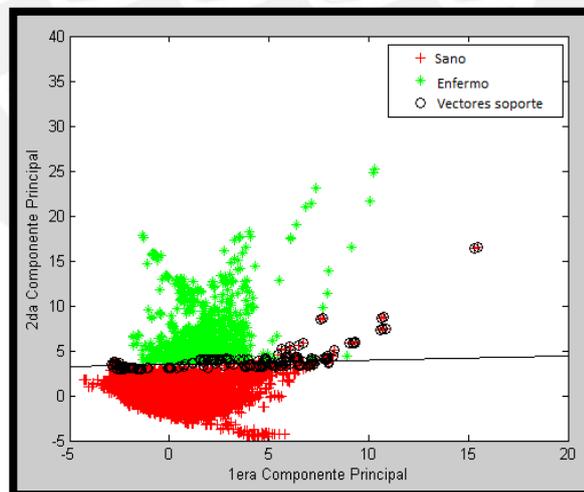


Figura 4.12. Conjunto de entrenamiento, sin considerar el primer video. Muestra el hiperplano de clasificación (lineal) y los vectores soporte.

En la **Tabla 4. 6.** se muestran, a modo de resumen, los resultados con kernel lineal en el conjunto de entrenamiento.

Tabla 4. 6. Resultados obtenidos mediante análisis PCA y SVM con kernel lineal en el conjunto de entrenamiento, indicando la sensibilidad, especificidad y exactitud.

C	Sensibilidad (%)	Especificidad (%)	Exactitud (%)
2±0.1	99±1	99±1	98±1

El algoritmo arrojó los siguientes resultados para el conjunto de prueba. Ver **Tabla 4. 7.**

Tabla 4. 7. Resultados obtenidos mediante análisis PCA y SVM con kernel lineal en el conjunto de prueba.

Sensibilidad	Especificidad	Exactitud
100%	98%	98%

A modo informativo, en la **Figura 4.13** se muestra la clasificación del conjunto de entrenamiento mostrado en la **Figura 4.12**, donde se usó kernel rbf con $C=2$ y $\sigma=0.2$. La sensibilidad, especificidad y exactitud obtenidas fueron de 100%, 98% y 98% respectivamente, los cuales son prometedores, pero por la complejidad en su procesamiento se decide seguir usando kernel lineal ya que este último tiene una duración de 2 segundos (aproximadamente 1 minuto menos que usando kernel rbf).

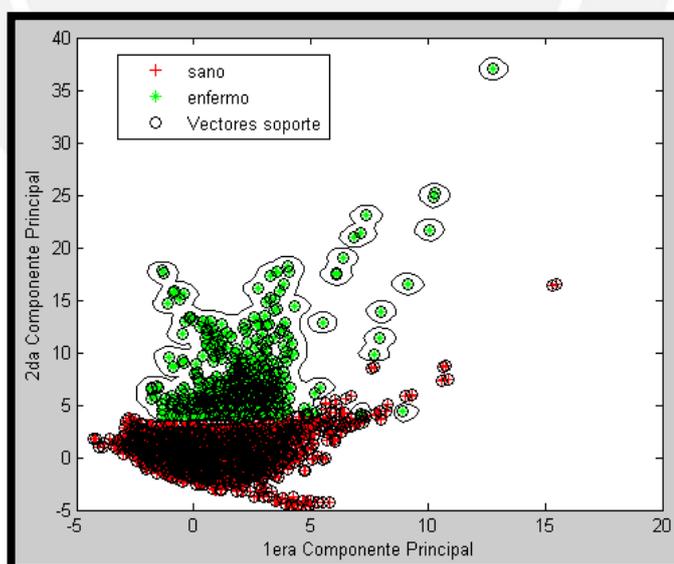


Figura 4.13. Conjunto de entrenamiento, sin considerar el primer video. Muestra la clasificación por kernel rbf y los vectores soporte.

El resumen de los resultados obtenidos mediante los tres métodos descritos anteriormente, se aprecia en la **Tabla 4.8.**

Tabla 4.8. Resultados obtenidos por Curva ROC, SVM, PCA (con SVM) en los conjuntos de prueba.

	ROC	SVM	PCA (con SVM)
Sensibilidad	77%	93%	100%
Especificidad	75%	86%	98%
Exactitud	75%	88%	98%

4.5 Discusión de los resultados obtenidos

La segmentación de la línea pleural, arroja un resultado prometedor en cuanto al error promedio obtenido (5.1 píxeles, ver **Tabla 4.1**), pues si lo comparamos con el alto del cuadro de video (462 píxeles), vamos a obtener un error de 1.1% tal como se muestra en:

$$e = \frac{5.1}{462} = 1.1\%$$

Este error garantiza un gran acercamiento de la segmentación de la pleura hecha por el algoritmo respecto a la verdadera ubicación de la zona pleural en el video.

En base a las 3 formas de analizar la base de datos, notamos claramente que el análisis para clasificar espacios intercostales sanos y enfermos, tendrá mejores resultados si analizamos tomando en consideración 5 características (PCA) y luego clasificando mediante SVM, en lugar de tomar solo 1 o 2.

4.5.1 Primer método de análisis (Curva ROC)

Para la clasificación de espacios intercostales entre sanos y enfermos, se obtuvo una sensibilidad, especificidad y exactitud distinguible, a partir de la discriminación por promedio, característica relacionada a la intensidad de grises (parte **a**) de la **sección 2.4.2**). A mayor valor de esta medida, la intensidad de grises de la imagen de interés (espacio intercostal) aumenta; hecho que coincide con la presencia de las líneas B.

4.5.2 Segundo método de análisis (máquina de vector de soporte)

Los resultados mejoraron respecto al análisis con solo una característica, permitiendo afirmar que la técnica de aprendizaje automático (máquina de vector de soporte) aplicada a 2 características resulta más conveniente.

4.5.3 Tercer método de análisis (máquina de vector de soporte y PCA)

Resultó ser la mejor técnica a emplear en este caso de clasificación, ya que se usaron 2 nuevas componentes que contenían la información de las 5 variables originales en simultáneo. Como consecuencia, la clasificación fue óptima.

Será el método final a usar.



Conclusiones

Los resultados revelan una clasificación óptima de espacios intercostales (mediante análisis de líneas B) utilizando un método de extracción y análisis de características matemáticas de los histogramas dentro del video.

Esto sugiere que, analizando todas las características matemáticas en simultáneo a través del tercer método, se obtienen sensibilidades, especificidades y exactitudes más altas que usando solo una de ellas.

Además, se logró extraer los espacios intercostales a partir de la segmentación de la pleura de manera automática mediante el uso de centroides. El error que presentó esta parte del algoritmo, fue en promedio de 5 píxeles. Teniendo en cuenta que el alto de la imagen es de 462 píxeles, estos resultados sugieren que el método podría ser útil como base de futuros trabajos en el tema.

Finalmente, la detección de líneas B mediante el tercer análisis (PCA y SVM) fue la más cercana al diagnóstico médico gracias a la correcta elección de las 5 variables a analizar, y arroja una sensibilidad, especificidad y exactitud de 100%, 98% y 98% respectivamente. Mientras que el análisis por el primer método (curva ROC) obtuvo una sensibilidad, especificidad y exactitud de 77%, 75% y 75% respectivamente, y por el segundo método (SVM), se obtuvo una sensibilidad, especificidad y exactitud de 93%, 86% y 88% respectivamente; valores menores que en el primer caso, pero igual de útiles para la clasificación requerida.

Estos resultados permiten afirmar que, en temas de clasificación, un algoritmo de entrenamiento y aprendizaje como SVM es de más utilidad y más confiable que el de análisis por curva ROC, ya que este hace uso de kernels de diverso tipo y permite la selección de parámetros que van a ajustar nuestro clasificador de acuerdo a la data que le proporcionemos. Así mismo, el uso de toda la información con que se cuenta puede ser analizada en simultáneo gracias a que la cantidad de dimensiones puede ser reducida y resumida (obteniendo la información más importante) mediante PCA.

Recomendaciones y consideraciones finales

Algunas tomas de los videos de la base de datos, presentaron defectos como sombras acústicas y desaparición de la imagen, por ello se recomienda mejorar la toma de los videos, de manera que la fuente de error en el diagnóstico no aumente.

Así mismo, en la sección de detección de la pleura es importante remarcar que cada uno de los pasos especificados para dicho fin fueron establecidos heurísticamente y en base a las tendencias que se observaron en el comportamiento del lugar geométrico de la pleura.

El tamaño de todas las imágenes de estudio es el mismo, sin embargo, se recomienda tener en cuenta la normalización de futuras imágenes de entrada que se deseen analizar mediante el proceso descrito.

El algoritmo desarrollado ha tenido resultados de exactitud mayores a 75%, con lo cual podría usarse como base para futuros estudios de detección de neumonía, de manera que el algoritmo se pruebe en nuevos datos y se analicen más características matemáticas, pues al analizar a escala de 2 o más variables, mostró resultados más confiables.

Se recomienda indagar en más de una opinión con respecto al diagnóstico, ya que, al ser un análisis subjetivo realizado por el especialista en radiología, la posibilidad de error puede desembocar en un diagnóstico equívoco, lo cual sería perjudicial para el estudio de los antecedentes si se quieren predecir acontecimientos (entrenamiento del algoritmo).

Además, es necesario explorar otros análisis que involucren muestras de sangre y síntomas como fiebre o dolores corporales en el paciente, a fin de que sirvan como complemento, y poder obtener un diagnóstico más completo que permita obtener resultados similares o mejores a este trabajo.

Finalmente, se recomienda analizar cuántos espacios intercostales clasificados como enfermos tienen que estar presentes en el video para que este sea considerado como paciente enfermo, y de este modo, se realice una clasificación ya no a nivel de espacios intercostales, si no a nivel de todo el video en su conjunto.

Bibliografía

- [1] Organización Panamericana de la salud. *Infección Respiratoria Aguda*. Consulta: 09 de setiembre de 2015.
- [2] World Health Organization 2014, *Fact Sheet N°331-Pneumonia*. Consulta: 20 de noviembre de 2015.
URL: <http://www.who.int/mediacentre/factsheets/fs331/en/>
- [3] Red Nacional de Epidemiología (RENACE) – DGE – MINSA. Consulta: 04 de mayo de 2016.
- [4] GUNDULA STAATZ. Department of Radiology, Division of Pediatric Radiology. Encyclopedia of Diagnostic Imaging. "Pneumonia in childhood". University of Erlangen-Nu"rnberg, Erlangen, Germany. PP 1514-1517.
- [5] Sartori S, Tombesi P: Emerging roles for transthoracic ultrasonography in pulmonary diseases. *World J Radiol* 2010, 2:203-214
- [6] American College of Emergency Physicians (ACEP): Emergency ultrasound guidelines. ACEP Policy Statements 2008, 1-38[<http://www.acep.org>].
- [7] Torres, A; Cillóniz, Catia. "Diagnosis and classification of pneumonia". *Clinical Management of Bacterial Pneumonia*, 2015, pp42.
- [8] Benseler, J.S. *The Radiology Handbook, a pocket guide to Medical Imaging*. Ohio University Press, 2006
- [9] ESCUELA DE MEDICINA. PONTIFICIA UNIVERSIDAD CATÓLICA DE CHILE. Publicaciones: "Aparato Respiratorio, fisiología y clínica". Capítulo 22. 6ta edición. 2015. Fecha de consulta: 17 de Setiembre de 2015
URL: <http://escuela.med.puc.cl/publ/Aparatorespiratorio/22Radiologia.html>
- [10] UNIVERSITY OF UTAH. HEALTH CARE. Health Library: Ultrasonido de tórax
Fecha de consulta: 25 de Setiembre de 2015
URL: <http://healthcare.utah.edu/healthlibrary/related/doc.php?type=92&id=P09260>
- [11] Matthew Jankowich Eric Gartman. *Ultrasound in the intensive Care Unit*. "Lung Ultrasound in Respiratory Failure and Pneumonia". Humana Press. New York 2015. PP 13. PP 191-230.

- [12] Lichtenstein,D, "Ultrasound diagnosis of alveolar consolidation in the critically ill". Intensive Care Medicine 2004 n.30 pp 276–281.
- [13] Evans N, Gournay V, Cabanas F, Kluckow M, Leone T, Groves A, et al. Point-of-care ultrasound in the neonatal intensive care unit: international perspectives. Semin Fetal Neonatal Med. 2011;16:61–8.
- [14] Mack LA, Wright K, Hirsch JH, Alvord EC, Guthrie RD, Shuman WP, et al. Intracranial hemorrhage in premature infants: accuracy in sonographic evaluation. AJR Am J Roentgenol. 1981;137:245–50.
- [15] Haase R, Hein M, Thale V, Vilser C, Merkel N. Umbilical venous catheters – analysis of malpositioning over a 10-year period. Z Geburtshilfe Neonatol. 2011;215:18–22.
- [16] Ohki Y, Maruyama K, Harigaya A, Kohno M, Arakawa H. Complications of peripherally inserted central venous catheter in Japanese neonatal intensive care units. Pediatr Int. 2013;55: 185–9.
- [17] Chavez, M. "Lung ultrasound for the diagnosis of pneumonia in adults: a systematic review and meta – analysis". Respiratory Research 2014 15:50.
- [18] Gallego Gómez,M.P. "Chest ultrasonography in pleurapulmonary disease". Radiología 2012 Volumen 56, n.1,pp 52-60.
- [19] Romero, S. "DETECCIÓN DE NEUMONÍA A TRAVÉS DE IMÁGENES DE ULTRASONIDO". 2014. Tesis de licenciatura en Ingeniería Electrónica. PUCP.
- [20] HOFER, MATTHIAS. Curso Básico de ecografía. Manual de iniciación. 4ta edición. Editorial Panamericana.
- [21] Zenteno, O. "Diseño de un sistema de formación de imágenes médicas ultrasónicas Modo-B". 2011. Tesis de licenciatura en Ingeniería Electrónica. PUCP.
- [22] Lichtenstein D, Mezie`re G, Lagoueyte J, Biderman P, Goldstein I, Gepner A. A-lines and B-lines: lung ultrasound as a bedside tool for predicting pulmonary artery occlusion pressure in the critically ill. Chest. 2009;136(4):1014–20.
- [23] Lichtenstein D, Mezière G. A lung ultrasound sign allowing bedside distinction between pulmonary edema and COPD: the comet-tail artifact. Intensive Care Med. 1998;24(12):1331–4.

- [24] Lichtenstein DA, Menu YA. Bedside ultrasound sign ruling out pneumothorax in the critically ill. Lung sliding. *Chest*. 1995;108(5):1345–8.
- [25] Lichtenstein DA, Lascols N, Prin S, Mezière G. The “lung pulse”: an early ultrasound sign of complete atelectasis. *Intensive Care Med*. 2003;29(12):2187–92.
- [26] Cerda, J. “Uso de tests diagnósticos en la práctica clínica (Parte 1). Análisis de las propiedades de un test diagnóstico.” *Revista chilena infectología*, 2010; Vol 27, n.3 pp 205-208.
- [27] Hanley J.A., McNeil B.J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*. **143**: 29-36
- [28] Hanley J.A., McNeil B.J. (1983). A method of comparing the areas under receiver operating characteristic curves derived from the same cases. *Radiology*. **148**: 839-43
- [29] LIU Yixin, GUO Yizheng. Feature extraction based on gray level histogram using MATLAB. *Computer knowledge and technology*. 2009,5(32):9032-9034.
- [30] Mathworks. Support vector machines for binary classification. Fecha de consulta: 16 de junio de 2016
URL: <http://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html#bsr5o3f>
- [31] JIN Hua. The research of segmentation and feature extraction method for medical images based on density clustering [D]. Master's degree dissertation. Zhenjiang: Jiangsu university, 2005.
- [32] Universidad Nacional de Colombia. Blog de Ingeniería Aplicada. Visión Artificial usando Matlab. Fecha de consulta: 3 de febrero de 2016.
URL: <http://alvarounal.blogspot.pe/2011/12/vision-artificial-usando-matlab-parte-1.html>
- [33] Universidad de los Andes. Colombia. Interpolación. Fecha de consulta: 5 de febrero d 2016.
URL: <http://www.prof.uniandes.edu.co/~gprieto/classes/compufis/interpolacion.pdf>
- [34] Gonzalez C.R., Woods E. R. *Digital Image Processing*. Nueva Jersey, 2008

[35] Mathematics Dictionary

Fecha de consulta: 17 de junio de 2016

URL: <http://www.mathematicsdictionary.com/spanish/vmd/full/c/centroid.htm>

[36] GeoCities Neighborhoods

Fecha de consulta: 17 de junio de 2016

URL: <http://www.oocities.org/collegetpark/grounds/3433/centroid.htm>

[37] V. Villena. Pleural Ultrasound Applications. Servicio de Neumología, Hospital Universitario 12 de octubre. Arch Bronconeumol. 2012. Madrid, Spain.

[38] Dr. Saed Sayad. An introduction to Data Mining.

Fecha de consulta: 10 de junio de 2016

URL: http://www.saedsayad.com/data_mining_map.htm

[39] Coursera. Machine learning. Gradient descent in Feature scaling

Fecha de consulta: 10 de marzo de 2016

URL: <https://www.coursera.org/learn/machine-learning/lecture/xx3Da/gradient-descent-in-practice-i-feature-scaling>

[40] MathWorks. How to buy. License options.

Fecha de consulta: 20 de Junio de 2016.

URL:

https://www.mathworks.com/store?s_cid=store_top_nav&s_tid=gn_store

[41] Organización Internacional del Trabajo (2012) “Los riesgos para la función reproductora del hombre y la mujer” en OIT.

Fecha de consulta: 23 de octubre del 2016.

URL: http://training.itcilo.it/actrav_cdrom2/es/osh/rep/remain.htm

[42] Redondo Antonio (2012) “Rayos X: pros y contras” en APEPA.

Fecha de consulta: 23 de octubre del 2016.

URL: http://www.apepa.org/index.php?menu=documentos&id=35&id_doc=413&show=1

[43] PANORAMA.COM.VE. “Esperé 20 días para hacerme una tomografía”. Maracaibo.

Fecha de consulta: 23 de octubre del 2016.

URL: <http://www.panorama.com.ve/ciudad/Espere-20-dias--para-hacerme-una-tomografia-paciente-20140402-0003.html>

[44] André Valerio Rao. Presentación: Formación de imagen en TC convencional

Fecha de consulta: 23 de octubre del 2016.

URL: <https://prezi.com/6bzmhnhuwaw4/formacion-de-la-imagen-por-tc/>

[45] Definición de ultrasonido - Qué es, Significado y Concepto.

Fecha de consulta: 23 de octubre del 2016.

URL: <http://definicion.de/ultrasonido/#ixzz4Nw1SRFKb>

[46] Carmona Suárez, Enrique. Tutorial sobre máquinas de Vectores Soporte (SVM). Universidad Nacional de Educación a distancia (UNED). Madrid.

Fecha de consulta: 23 de octubre del 2016.

URL: [http://www.ia.uned.es/~ejcarmona/publicaciones/\[2013-Carmona\]%20SVM.pdf](http://www.ia.uned.es/~ejcarmona/publicaciones/[2013-Carmona]%20SVM.pdf)

[47] González, Carlos. Grupo de sistemas inteligentes, Departamento de Informática. Universidad de Valladolid. "SVM: Máquinas de vectores soporte".

Fecha de consulta: 05 de diciembre del 2016.

URL: <https://www.infor.uva.es/~calonso/MUI-TIC/MineriaDatos/SVM.pdf>

[48] Biblioteca de ingeniería. Escuela técnica superior de Ingeniería. Universidad de Sevilla. "Detección Multiusuario para DS-CDMA basado en SVM".

Fecha de consulta: 10 de diciembre del 2016.

URL:

http://bibing.us.es/proyectos/abreproy/11185/fichero/Volumen+1_Detector+Multiusuario+para+DS-CDMA+basado+en+SVM%252F7.+Support+Vector+Machines%252FSupport+Vector+Machines.pdf

[49] Universidad autónoma de Madrid. Universidad Carlos III de Madrid, Departamento de Teoría de la señal y comunicaciones. "Introducción a los métodos Kernel".

Fecha de consulta: 10 de diciembre del 2016.

URL: http://arantxa.ii.uam.es/~jms/seminarios_doctorado/abstracts2007-2008/20080429MMartinez.pdf

[50] DRGEN. Ciencia y pensamiento crítico. "Así funciona un tomógrafo computado".

Fecha de consulta: 10 de diciembre del 2016.

URL: <http://www.drigen.com.ar/2012/11/como-funciona-tomografo/>

[51] Universidad de Otago. Nueva Zelanda. Departamento de Ciencias de la computación. "A tutorial on principal component analysis".

Fecha de consulta: 10 de Agosto del 2017.

URL:

http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf

[52] Instituto Nacional de Astrofísica óptica y electrónica. Puebla, México. "Clasificación supervisada. Técnicas de validación".

Fecha de consulta: 10 de Agosto del 2017.

URL: <https://ccc.inaoep.mx/~ariel/TecnicasDeValidacion2011.pdf>

[53] Lobo, V "Thoracic Ultrasonography". Critical Care Clinics, 2013, Vol. 30 Issue 1, pp 93-117.

[54] Szabo, Thomas L. Diagnostic ultrasound imaging. "Ultrasound and other diagnostic modalities". PP22-26.

