



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO  
POSGRADO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

APRENDIZAJE PROFUNDO EN EL ANÁLISIS DE DEFORMACIÓN DEL VENTRÍCULO  
IZQUIERDO EN ECOCARDIOGRAMAS 2D

**TESIS**

QUE PARA OPTAR POR EL GRADO DE  
MAESTRO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

PRESENTA:

**ALAN GABRIEL ROMERO PACHECO**

TUTORES:

DR. JORGE LUIS PÉREZ GONZÁLEZ  
INSTITUTO DE INVESTIGACIONES EN MATEMÁTICAS APLICADAS Y EN SISTEMAS

DRA. NIDIYARE HEVIA MONTIEL  
INSTITUTO DE INVESTIGACIONES EN MATEMÁTICAS APLICADAS Y EN SISTEMAS



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

# Agradecimientos

Me gustaría agradecer a mis asesores quienes me apoyaron a lo largo de este proceso; desde el planteamiento de la investigación hasta la discusión de los resultados, dando la pauta para avanzar y terminar en tiempo y forma la tesis. Así mismo, me gustaría agradecer a CONACYT por el soporte financiero que me brindó a través de una beca con número de apoyo 785761 a lo largo de la maestría. Finalmente, me gustaría agradecer especialmente a mis padres y a mi novia por su apoyo incondicional a lo largo de estos 2 años. Investigación realizada gracias al Programa de Apoyo a Proyectos de Investigación e Innovación Tecnológica (PAPIIT) de la UNAM IA104622 e IT101422. Agradezco a la DGAPA-UNAM la beca recibida.

# Resumen

Las enfermedades cardiovasculares son de gran importancia para los organismos de salud pública mundiales, pues representan aproximadamente un tercio (30.9 %) de la mortalidad de pacientes en todo el mundo. Para reducir la mortalidad de estas enfermedades es crucial enfocarse en la detección temprana de dichas enfermedades a través de índices de función cardíaca. Últimamente ha habido un gran interés en los índices basados en el análisis de deformación de las paredes cardíacas, como el índice de deformación longitudinal global, debido a su habilidad para detectar patologías cardíacas en su etapa subclínica, mientras otros índices como la fracción de eyección se mantienen preservados. El estado del arte de algoritmos para la estimación de deformación en las paredes cardíacas usando imágenes de ecocardiografía, mejor conocidos como *Speckle Tracking Echocardiography (STE)*, se basan en distintas familias de algoritmos de seguimiento como *Block Matching*, registro elástico de imágenes y flujo óptico, donde los algoritmos de flujo óptico reportan un mejor rendimiento considerando la certeza y la rapidez. En el abordaje de flujo óptico existen distintos problemas importantes que tienen que ser resueltos como las oclusiones y la inconsistencia en el brillo. En ecocardiogramas transtorácicos 2D, las oclusiones y la inconsistencia de brillo pueden ser causados por el ruido acústico conocido también como *speckle* (ruido de moteado o de sal y pimienta), que es un ruido de tipo multiplicativo, movimiento de las cavidades fuera del plano de adquisición, sombreados acústicos y por la deformación de la cavidad debido movimientos de compresión, expansión, corte o rotación. En este trabajo presentamos una nueva metodología basada en EchoPWC-Net-us [1], que integra una arquitectura de aprendizaje profundo especializada en la estimación de flujo en fotogramas con oclusiones en imágenes de ecocardiografía. El método propuesto alcanzó un error promedio de punto final promedio de  $0.14 \pm 0.17$  píxeles en la estimación de flujo en las paredes del ventrículo izquierdo. Además, una de las variantes del método propuesto ob-

tuvo mejores figuras de mérito que los algoritmos del estado del arte, dichas figuras de mérito se evaluaron en una base de datos sintética, la cual ha sido ampliamente usada para comparar los algoritmos de **STE** [2,3]. Adicionalmente, se validó la estabilidad ante artefactos del error en la estimación del índice de deformación longitudinal global, evaluando si existía diferencia significativa en el error al ser estimado dicho índice en el conjunto de prueba con aumento y sin aumento de datos (con artefactos sintéticos de ultrasonido). Este trabajo se limitó a validar la metodología propuesta en una base de datos sintética, por lo que el trabajo futuro se debe de enfocar en validar dicha metodología con una base de datos de pacientes reales con anotaciones de un especialista.

# Abstract

Cardiovascular diseases have a great impact on health organizations, since a third of mortality worldwide is due to these diseases. To reduce mortality, it is necessary to detect these diseases early through the use of different indices of cardiac function. Lately, there has been great interest in obtaining myocardial longitudinal strain indices such as global longitudinal strain due to its ability to detect different cardiac pathologies in the subclinical stage while other indices such as the ejection fraction keep preserved. The state of the art of Speckle Tracking algorithms for estimating echocardiographic myocardial strain has greatly increased with many method variants such as block matching, elastic image registration and optical flow, where Optical flow methods are the most efficient considering accuracy and speed. In the optical flow approach, there are certain problems known as occlusions and brightness inconsistency, that can be caused by the acquisition process or by the phenomenon being measured. In transthoracic 2D echocardiogram occlusions and brightness inconsistency can be caused by the acoustic noise known as speckle noise, out of plane motion and acoustic shadow that can be present in the acquired frames. Distortion can also be caused by the cardiac tissue making certain type of motion and deformation such as compression, expansion, shearing or rotation. Recently, Østvik *et al.* proposed a Speckle Tracking algorithm known as EchoPWC-Net-us that is a variant of PWC-Net, where PWC-Net is a convolutional neural network designed to solve optical flow problems. In this Deep Learning approach of Speckle Tracking the authors validated a greater stability than traditional optical flow algorithms like Farneback in the estimation of motion between 2 frames despite the addition of synthetic artifacts such as shadows, depth attenuation and haze. In this work, we present a new Speckle Tracking pipeline based in EchoPWC-Net-us that integrates a deep learning architecture specialized in the estimation of motion on echocardiographic frames with occlusions. The proposed method equals the per-

formance of the best reviewed method of the state of the art without losing stability with noisy echocardiograms and achieved an average end point error of  $0.14 \pm 0.17$  pixels in the estimation of the flow in the myocardium of the left ventricle and an error of  $1.34 \pm 2.34\%$  in the estimation of the global longitudinal strain indicator when it is evaluated on a synthetic echocardiographic dataset.

# Índice general

<b>1. Introducción</b>	<b>13</b>
1.1. Estado del arte . . . . .	16
1.1.1. Trabajos de STE que emplean aprendizaje profundo . . . . .	19
1.2. Planteamiento del problema . . . . .	23
1.3. Justificación . . . . .	24
1.4. Hipótesis . . . . .	24
1.5. Objetivos . . . . .	25
1.5.1. Objetivo General . . . . .	25
1.5.2. Objetivos Específicos . . . . .	25
<b>2. Marco Teórico</b>	<b>26</b>
2.1. Anatomía, fisiología y patologías del corazón . . . . .	26
2.1.1. Ciclo cardíaco . . . . .	26
2.1.2. Anatomía funcional del ventrículo izquierdo . . . . .	27
2.1.3. Enfermedad Coronaria . . . . .	28
2.1.4. Cardiomiopatía Diabética . . . . .	29
2.1.5. Enfermedad Valvular . . . . .	29
2.1.6. Enfermedades Pericárdicas . . . . .	29
2.2. Índices de función cardíaca . . . . .	30
2.2.1. Tamaño del VI . . . . .	31
2.2.2. Fracción de eyección del VI . . . . .	32
2.2.3. Análisis de deformación . . . . .	32
2.3. Técnicas de imagenología para el análisis de deformación . . . . .	35

<i>ÍNDICE GENERAL</i>	7
2.3.1. Ecocardiografía . . . . .	35
2.3.2. Resonancia Magnética Cardíaca . . . . .	37
2.3.3. Tomografía Computarizada . . . . .	38
2.4. Aprendizaje profundo . . . . .	39
2.4.1. Redes Neuronales Convolucionales . . . . .	40
2.4.2. Redes Neuronales Recurrentes . . . . .	41
2.5. Flujo óptico . . . . .	44
<b>3. Materiales y Métodos</b>	<b>46</b>
3.1. Bases de datos . . . . .	48
3.1.1. Base de datos sintética . . . . .	48
3.1.2. Base de datos CAMUS . . . . .	49
3.1.3. Aumento de datos . . . . .	52
3.2. Convertidor de flujo disperso a denso (SDC) . . . . .	53
3.3. Arquitectura para la estimación de flujo (GMA) . . . . .	56
3.4. Arquitectura para la segmentación de la ROI (ROI-Seg) . . . . .	60
3.5. Análisis de deformación (AD) en la ROI . . . . .	62
<b>4. Resultados y Discusión</b>	<b>65</b>
4.1. Aumento de datos . . . . .	65
4.2. Validación del SDC . . . . .	66
4.3. Validación de la arquitectura GMA . . . . .	67
4.4. Validación de la arquitectura ROI-Seg . . . . .	71
4.5. Validación de la etapa de AD . . . . .	72
<b>5. Conclusiones y Trabajo Futuro</b>	<b>76</b>
<b>Referencias</b>	<b>76</b>

# Índice de figuras

1.1.	Arquitectura de la CNN PWC-Net. . . . .	20
2.1.	El ciclo cardíaco empieza con la sístole auricular, después con la sístole ventricular, luego con la diástole auricular y finalmente con la diástole ventricular, Figura modificada y tomada de [4]. . . . .	27
2.2.	En esta figura se ilustra un acortamiento de los sarcómeros de alrededor del 13 %, resultando en una fracción de eyección del VI del 60 %, lo anterior se atribuye a el arreglo de fibras en forma de doble hélice [5]. . . . .	28
2.3.	Medición del tamaño del ventrículo izquierdo desde diferentes vistas: (a) apical de 4 cámaras, (b) eje corto paraesternal y (c) eje largo paesternal [6]. . . . .	31
2.4.	En el inciso (a) se ilustran los distintos segmentos sobre los que se evalúa la deformación en las paredes del ventrículo izquierdo [7]. En el inciso (b) se aprecian los distintos contornos sobre los que se estima la deformación en la componente radial (Cp) y longitudinal (Ct) en un ecocardiograma 2D. . . . .	33
2.5.	En esta figura se aprecia un ejemplo de los resultados obtenidos mediante STE en un ecocardiograma 2D. La parte de arriba de la figura se aprecia una malla de puntos clave sobre los cuales se hace el seguimiento y se estima la deformación por segmento. En la parte de abajo se presentan las distintas curvas de deformación para cada segmento, donde cada segmento tiene un color asociado [8]. . . . .	34
2.6.	Diagrama del pecho humano ilustrando el posicionamiento de los transductores en las ventanas de exploración estándar del TTE [9]. . . . .	36
2.7.	Red neuronal artificial de una capa. . . . .	39

2.8.	Bloque convolucional como unidad base de las CNN. . . . .	41
2.9.	RNN sin salidas, donde se hace explícita la recurrencia sobre la unidad oculta $\mathbf{h}$ en cada instante de tiempo mediante una función $f$ , este grafo representa la ecuación 2.5 [10]. . . . .	42
2.10.	Diagrama de una GRU, donde $\mathbf{z}$ es la compuerta de actualización que establece si el estado de la unidad oculta $\mathbf{h}$ va a actualizarse con un nuevo estado $\tilde{\mathbf{h}}$ y $\mathbf{r}$ es la compuerta de reinicio, la cual establece si se ignoran estados de la unidad oculta del pasado [11]. . . . .	43
3.1.	Diagrama de bloques del algoritmo de STE implementado. Donde se denotan las bases de datos como BD y los ecocardiogramas como ecos. Además, las bases de datos, y, las etapas del convertidor de flujo disperso a denso (SDC), de la arquitectura para la estimación de flujo (GMA), de la arquitectura para la segmentación de la ROI (ROI-Seg) y del análisis de deformación (AD) se explican con detalle en las secciones 3.1, 4.2, 3.3, 3.4 y 3.5, respectivamente. . .	47
3.2.	Ejemplo de un fotograma de un registro en la vista A4C de la base de datos sintética con su arreglo de puntos clave ordenados a lo largo de la ROI. Los puntos clave se visualizan con distintos colores dependiendo del segmento asociado. .	49
3.3.	Anotaciones de las distintas cavidades cardíacas en el final de la diástole (a) y el final de la sístole (b), ambas anotaciones son en la vista A4C [12]. . . . .	50
3.4.	Diagramas de bloques de los 3 algoritmos desarrollados para la conversión de flujo disperso a flujo denso. . . . .	55
3.5.	Arquitectura RAFT estimando el flujo entre dos fotogramas de la base de datos sintética [13]. . . . .	58
3.6.	Arquitectura GMA, la cual se basa en la arquitectura RAFT [14]. . . . .	58
3.7.	Arquitectura del modelo ROI-Seg basado en U-Net y ResNet. . . . .	61
4.1.	Aumento de un ecocardiograma de la base de datos sintética en la vista A4C, el aumento consiste de ruido <i>speckle</i> y sombreados gaussianos. . . . .	66
4.2.	Imágenes de flujo denso estimado a partir de los distintos convertidores de flujo desarrollados. . . . .	66

4.3.	Convergencia de los valores de pérdida (EPE). . . . .	68
4.4.	Campo de desplazamiento estimado con el modelo GMA a partir de 2 fotogramas consecutivos del conjunto de prueba aumentado y el campo de desplazamiento de referencia. Ambos campos de desplazamiento se visualizan en el mapa de colores HSV, representando con la tonalidad la fase del vector de desplazamiento y la saturación para la magnitud de dicho vector. En los fotogramas se indica con un recuadro la región que tiene oclusiones generadas por artefactos de sombreado acústico sintético. . . . .	69
4.5.	Comparación del EPE entre el modelo GMA, Augmented-GMA y el algoritmo de Farneback mediante un diagrama de cajas y bigotes, la evaluación se llevó a cabo sobre el conjunto de prueba aumentado y sin aumento. . . . .	70
4.6.	Exactitud del modelo obtenida durante cada época del entrenamiento para el conjunto de entrenamiento y validación. . . . .	71
4.7.	Se presentan las curvas de deformación longitudinal a lo largo de la secuencia de fotogramas de un registro sintético de un paciente normal en la vista A4C. El inciso a) corresponde a las curvas de referencia, el inciso b) presenta las curvas estimadas por el algoritmo de <b>STE</b> GMA-ST y el inciso c) muestra las curvas de deformación obtenidas mediante el algoritmo de Farneback. . . . .	73

# Índice de tablas

1.1. Comparación de las características de todos los algoritmos de <b>STE</b> presentados en el estado del arte. . . . .	22
2.1. Comparación entre las distintas técnicas de imagenología [15]. . . . .	38
3.1. Características de las bases de datos utilizadas. . . . .	51
3.2. Conjuntos de la BD sintética sin aumento y con aumento, los cuales se usaron para entrenar el modelo GMA y Augmented-GMA, respectivamente. . . . .	59
3.3. Distribución de base de datos CAMUS aumentada para el entrenamiento, validación y prueba del algoritmo de segmentación. . . . .	62
4.1. Comparación de métricas de similitud entre SDC-1 y SDC-3 para 3 distintos métodos de interpolación. . . . .	67
4.2. Métricas para evaluación del algoritmo de segmentación calculadas sobre el conjunto de prueba (7,200). . . . .	72
4.3. Comparación entre los algoritmos de <b>STE</b> propuestos y los algoritmos revisados en el estado del arte, usando como figuras de mérito la pendiente de la regresión lineal ajustada ( $\alpha$ ), el coeficiente de correlación ( $\rho$ ), la ordenada de la regresión ( $\mu$ ) y el límite de concordancia de la regresión con un 95 % de nivel de confianza (LOA). Ésto fue evaluado sobre toda la base de datos sintética sin aumento (2,037) . . . . .	74

4.4. Intervalos de confianza del error obtenido en la estimación del GLS entre los algoritmos de **STE** implementados para el conjunto de prueba aumentado y sin aumento de datos. El símbolo \* denota si la diferencia entre los GLS estimados es significativa. . . . . 75

# Capítulo 1

## Introducción

Las enfermedades cardiovasculares son de gran importancia para los organismos de salud pública mundiales, pues representan aproximadamente un tercio (30.9 %) de la mortalidad de pacientes en todo el mundo [16].

El corazón es una estructura con 4 cámaras: aurícula izquierda (AI), aurícula derecha (AD), ventrículo izquierdo (VI) y ventrículo derecho (VD). Dicha estructura, funcionalmente puede verse como 2 bombas acopladas en serie; las cámaras derechas que bombean la sangre de las venas hacia el sistema circulatorio pulmonar para oxigenar la sangre y las cámaras izquierdas que bombean la sangre oxigenada hacia la circulación sistémica por medio de la arteria aorta [4]. Las cámaras cardíacas están formadas por el tejido cardíaco, llamado miocardio. La relajación y contracción de dichas cámaras es un proceso complejo que depende de la contractilidad, condiciones hemodinámicas, suministro de oxígeno, electrofisiología del miocardio y el funcionamiento de las válvulas cardíacas. Alguna afectación a cualquiera de los elementos mencionados puede resultar en anormalidades en el tamaño de las cámaras, movimiento de las paredes de las cámaras, grosor de las paredes de las cámaras y/o fracción de eyección (FE) de la cámara. Por consecuente, para la evaluación del correcto funcionamiento del corazón distintos autores han propuesto índices para la detección y cuantificación de dichas anormalidades [17].

Últimamente ha habido un gran interés en los índices basados en el análisis de deformación de las paredes cardíacas, como el índice de deformación longitudinal global (GLS, por

sus siglas en inglés), debido a su habilidad para detectar patologías cardíacas en su etapa sub-clínica, mientras otros índices como la fracción de eyección se mantienen preservados [18–21].

El análisis de deformación inicialmente se realizaba a partir de registros ecocardiográficos, hoy en día se realiza para distintas técnicas de imagenología, para mayor detalle consultar la sección 2.3. En este trabajo se trabajará con registros de ecocardiografía, debido a que es una técnica de imagenología no ionizante, que no está limitada en pacientes con dispositivos intracardíacos y cuenta con la mejor resolución temporal [15]. El análisis de deformación consiste en obtener la deformación Lagrangiana para cada fotograma, esto sobre los distintos segmentos de las paredes del ventrículo izquierdo, este trabajo se enfocará en la estimación de la deformación en la componente longitudinal (a lo largo de la pared cardíaca). La deformación se calcula para los distintos contornos (endocardio (capa interna del tejido cardíaco), centro y epicardio (capa externa del tejido cardíaco)) de las paredes cardíacas, para mayor detalle consultar la sección 2.2.

En el estado del arte se han empleado algoritmos de *Speckle Tracking* para la estimación de la deformación en las paredes cardíacas, éstos se basan en distintas familias de algoritmos de seguimiento como *Block Matching*, registro elástico de imágenes y flujo óptico [2, 3, 22–25]. Donde los algoritmos de flujo óptico reportan un mejor rendimiento considerando la certeza y la rapidez. En el abordaje de flujo óptico existen distintos problemas importantes que tienen que ser resueltos como las oclusiones y la inconsistencia en el brillo. En ecocardiogramas transtorácicos 2D, las oclusiones y la inconsistencia de brillo pueden ser causados por el ruido acústico conocido también como *speckle* (ruido de moteado o de sal y pimienta), que es un ruido de tipo multiplicativo, movimiento de las cavidades fuera del plano de adquisición, sombreados acústicos y por la deformación de la cavidad debido movimientos de compresión, expansión, corte o rotación [26]. En este trabajo se tiene como objetivo desarrollar una nueva metodología basada en EchoPWC-Net-us [1], que integre una arquitectura de aprendizaje profundo especializada en la estimación de flujo en fotogramas con oclusiones en imágenes de ecocardiografía. Ésto con el objetivo de poder estimar los indicadores de deformación de manera confiable para la evaluación del funcionamiento cardíaco.

En la sección 1.1 se revisarán los algoritmos del estado del arte empleados para la extracción de índices de deformación en registros de ecocardiografía. De la misma manera, en la sección 2.4 se revisarán trabajos similares en los que se extraigan los índices de deformación mediante algoritmos de aprendizaje profundo. En el resto del Capítulo 1 se plantea el problema del trabajo de tesis, la justificación, los objetivos y la hipótesis.

En la primera sección del Capítulo 2 se hablará sobre la fisiología y anatomía del corazón, principalmente del ventrículo izquierdo. Terminando dicha sección con una revisión de las principales enfermedades cardiovasculares, resaltando la afectación que causan estas enfermedades en el tejido cardíaco del ventrículo. Después se abordarán los principales índices de función cardíaca, detallando principalmente el procedimiento estandarizado por la sociedad europea y americana de cardiología para la extracción de indicadores de deformación. Posteriormente, se mencionarán y compararán las principales técnicas de imagenología usadas para la extracción de índices de deformación. Finalmente, para terminar la revisión del marco teórico se revisarán los fundamentos del aprendizaje profundo y de algoritmos de flujo óptico.

Para el Capítulo 3 se especificarán las distintas bases de datos empleadas. Adicionalmente, se detallará la metodología presentada, donde la etapa más importante es la arquitectura de aprendizaje profundo encargada de estimar el flujo óptico, permitiendo propagar los desplazamientos de los distintos segmentos de la cavidad cardíaca para calcular la deformación en dichos segmentos. Se validarán los modelos entrenados así como la metodología planteada mediante una comparación de distintas métricas con los algoritmos del estado del arte revisados en la sección 1.1. Finalmente, se validará en el resto del escrito la estabilidad que tiene el método propuesto ante registros de ecocardiogramas con presencia de ruido, ya que se tiene como hipótesis que las arquitecturas de aprendizaje profundo brindan cierta robustez en ese sentido.

## 1.1. Estado del arte

En esta sección se aborda el estado del arte de los algoritmos de **STE** para imágenes de ultrasonido 2D que no utilizan aprendizaje profundo. El primer algoritmo de **STE** a presentar es un algoritmo que se basa en registro elástico [3]. El mencionado algoritmo parametriza el campo de desplazamiento entre fotogramas consecutivos mediante coeficientes de interpolación cúbica (B-spline), los coeficientes son ajustados después de un proceso de optimización iterativa con una función de costo definida como  $C = S + wR$ , donde  $S$  es una medida de similitud calculada a partir de la suma de las diferencias al cuadrado (SSD, por sus siglas en inglés) de las intensidades entre fotogramas consecutivos,  $w$  denota los parámetros libres a ajustar, y  $R$  es un término de regularización que se obtiene a partir de la energía de flexión del campo de desplazamiento. Este algoritmo fue probado con una base de datos sintética con ecocardiogramas que simulan patrones de movimiento en las paredes del ventrículo, dicha base de datos es de acceso libre y fue generada en el mismo trabajo con el objetivo de evaluar la exactitud del algoritmo propuesto, la base de datos será explicada con detalle en la sección 3.1. Para evaluar la exactitud, se obtuvo el coeficiente de correlación de Pearson que existe entre la deformación obtenida con el algoritmo de **STE** y la deformación real que se tiene a partir del modelo que soporta los ecocardiogramas sintéticos. Finalmente, se obtuvo que las deformaciones estimadas por el algoritmo y las deformaciones de referencia están correlacionadas de manera significativa con un coeficiente de correlación promedio de 0.75.

Alessandrini *et al.* [2] plantearon un estudio que tuvo como objetivo principal comparar el rendimiento de 5 algoritmos no comerciales de **STE** en ecocardiogramas 3D sintéticos con un modelo biomecánico realista del movimiento de las cavidades cardíacas [27]. A continuación, se describen de manera breve los algoritmos y se discuten los resultados del rendimiento. El primer algoritmo fue desarrollado por Alessandrini *et al.* [23] y se conoce como algoritmo de deformación anatómica de forma libre (AFFD, por sus siglas en inglés); la primera etapa del algoritmo consiste de una segmentación manual del endocardio y el epicardio, en la segunda etapa se plantea una transformación que mapea del espacio cartesiano al espacio anatómico (con los ejes radial, longitudinal y circunferencial). En la tercera etapa estimaron el campo de

desplazamiento a partir del registro de fotogramas consecutivos mediante el producto tensorial de funciones B-spline, usando como malla tridimensional de puntos control la segmentación del endocardio. La última etapa contempla la transformación del espacio anatómico al espacio cartesiano para calcular la deformación. El algoritmo tiene una etapa de optimización que usa como función de costo la SSD, la penalización de suavizado y la conservación del volumen. Los autores obtuvieron un coeficiente de correlación promedio de 0.84, 0.98 y 0.93 para el caso de la deformación longitudinal, circunferencial y radial, respectivamente. El algoritmo se implementó en C++ en un CPU de 1.8 GHz y 256 GB de RAM, el tiempo de ejecución fue de aproximadamente 10 minutos por fotogramas consecutivos.

Queirós *et al.* [22] desarrollaron un algoritmo de flujo óptico afin anatómicamente restringido (AAOF, por sus siglas en inglés) para **STE** en 3D. La primera etapa del algoritmo contempla la segmentación automática del miocardio del VI, la cual se realiza mediante una binarización multinivel por umbral y una detección de objetos elípticos. Posteriormente, los autores extrajeron la superficie del ventrículo mediante un algoritmo de superficies activas con funciones B-spline. La siguiente etapa del algoritmo estima el desplazamiento afin de los puntos del contorno, basándose en la solución de la ecuación de flujo óptico y en la minimización de un modelo de energía. Para reducir el tamaño del problema, se acotó la región de interés (ROI, por sus siglas en inglés) anatómica mediante una expresión que incluye una función de vecindario y las distancias angulares relativas. Este algoritmo al ser probado con la base de datos sintética antes mencionada destacó con coeficientes de correlación de 0.95, 0.98 y 0.83 para el caso de la deformación longitudinal, circunferencial y radial, respectivamente. La implementación del algoritmo fue desarrollada en MATLAB en un CPU de 4 núcleos y 3.60 GHz, el tiempo de ejecución fue de 3.8 segundos por fotogramas consecutivos.

El siguiente algoritmo de **STE** implementado fue propuesto por un equipo de investigación de Philips [25]. Este algoritmo estima el campo de desplazamiento no rígido óptimo, minimizando una función de energía sobre la malla de puntos clave estandarizados a lo largo del endocardio [7], mediante descenso por gradiente. El campo de desplazamiento estimado es suavizado mediante un kernel gaussiano, donde el valor de la varianza es ajustado como pará-

metro libre del algoritmo. Este algoritmo obtuvo coeficientes de correlación de 0.88, 0.98 y 0.83 para la deformación longitudinal, circunferencial y radial, respectivamente. Éste se ejecutó en un CPU de 2.70 GHz con 16 GB de RAM y se tuvo un tiempo de ejecución de 0.08 segundos por fotogramas consecutivos.

El algoritmo de *Block Matching* (BM) tradicional consiste en obtener un vector de desplazamiento para cada patrón de píxeles en un fotograma actual respecto al fotograma consecutivo, dicho vector de desplazamiento se obtiene buscando dentro de una ventana en el fotograma consecutivo el patrón de píxeles que optimice una función de costo, la cual puede ser una métrica de similitud, para de esa manera estimar el campo de vectores de desplazamiento de los fotogramas consecutivos. Azarmehr *et al.* [24] propusieron un algoritmo de **STE** que se deriva del algoritmo BM tradicional, el cual utiliza una función de costo que contempla la SSD y un término de penalización que evalúa la discontinuidad del campo de vectores de desplazamiento de un vecindario, donde un vecindario está dado por un conjunto de patrones de píxeles. Para obtener el término de penalización en un vecindario se suaviza el campo de vectores de desplazamiento con un filtro de medianas cuyo núcleo es del tamaño del vecindario, después se obtiene el vector de desplazamiento promedio que representa el vector de desplazamiento de todos los patrones de píxeles en un vecindario. Finalmente, el término de penalización es obtenido de la suma de las diferencias entre el vector de desplazamiento promedio y los desplazamientos potenciales para cada patrón de píxeles en la ventana de búsqueda. Los autores evaluaron el algoritmo de **STE** con la misma base de datos sintética del algoritmo anteriormente revisado y se obtuvo un coeficiente de correlación promedio de 0.97, siendo más alto que el algoritmo anterior. Sin embargo, una desventaja de este algoritmo es la complejidad computacional debido a que en un CPU Intel Xeon E5630 el tiempo para estimar el campo de vectores de desplazamiento entre fotogramas consecutivos es de 10 segundos [24].

Por último se presenta un algoritmo de **STE** basado en un algoritmo de BM, que emplea la correlación cruzada normalizada como función de costo, para aumentar la resolución espacial de los voxels se empleó una interpolación tridimensional usando funciones B-spline cúbicas, después de obtener el campo de desplazamiento para cada fotograma de la secuencia suaviza-

ron temporalmente con un filtro gaussiano. El algoritmo obtuvo coeficientes de correlación de 0.75, 0.89 y 0.47 para la deformación longitudinal, circunferencial y radial, respectivamente. El algoritmo de BM fue ejecutado en MATLAB en un CPU Intel i7 con 6 GB de RAM y el tiempo de ejecución fue de 129 segundos por fotogramas consecutivos [2].

### 1.1.1. Trabajos de STE que emplean aprendizaje profundo

En esta sección se detallarán los algoritmos de STE que emplean aprendizaje profundo. Recientemente, se han desarrollado distintas arquitecturas de CNN [28–30] para resolver problemas de flujo óptico de distintos objetos en desplazamiento de distintas bases de datos sintéticas, demostrando una gran eficiencia, en especial la arquitectura PWC-Net. Esta arquitectura se aprecia en la Figura 1.1 y se caracteriza por las siguientes etapas: a la entrada de la red se tienen dos imágenes consecutivas  $I_t$  y  $I_{t+1}$ , como primer etapa se construye una representación piramidal de características, donde cada mapa de características es reducido a la mitad del tamaño del mapa anterior mediante filtros convolucionales, iniciando con el tamaño de la resolución de las imágenes crudas. Para cada mapa de características de  $I_{t+1}$  se le acopla una capa de deformación que primero realiza una interpolación bilineal para incrementar el tamaño de la matriz de desplazamiento  $\mathbf{W}$  al doble y deformar el mapa de  $I_{t+1}$  hacia el mapa de  $I_t$  en cada uno de los niveles de la pirámide de características. Se inicializa el mapa de desplazamiento  $\mathbf{W}$  como cero en la capa de características más pequeña, y se actualizará de manera recursiva la estimación de  $\mathbf{W}$  en cada capa consecutiva, además para cada nivel de la pirámide se acopla una capa de volumen de costo que evalúa la correlación cruzada entre el mapa de características de  $I_t$  y el mapa de  $I_{t+1}$  deformado para distintos desplazamientos pequeños entre ambos mapas. Para estimar la matriz de desplazamiento  $\mathbf{W}$  de la siguiente capa se utiliza una red DenseNet, esta red recibe como entrada el mapa de características de  $I_t$  en el nivel actual, así como la matriz  $\mathbf{W}$  de la capa actual y el volumen de costo. En esta propuesta  $\mathbf{W}$  es refinado hasta la segunda capa piramidal, estimando  $\mathbf{W}$  a un cuarto de la resolución de las imágenes crudas. Como última etapa se acopla una red prealimentada con capas de convoluciones de dilatación para el post procesamiento de la matriz de desplazamiento estimada.

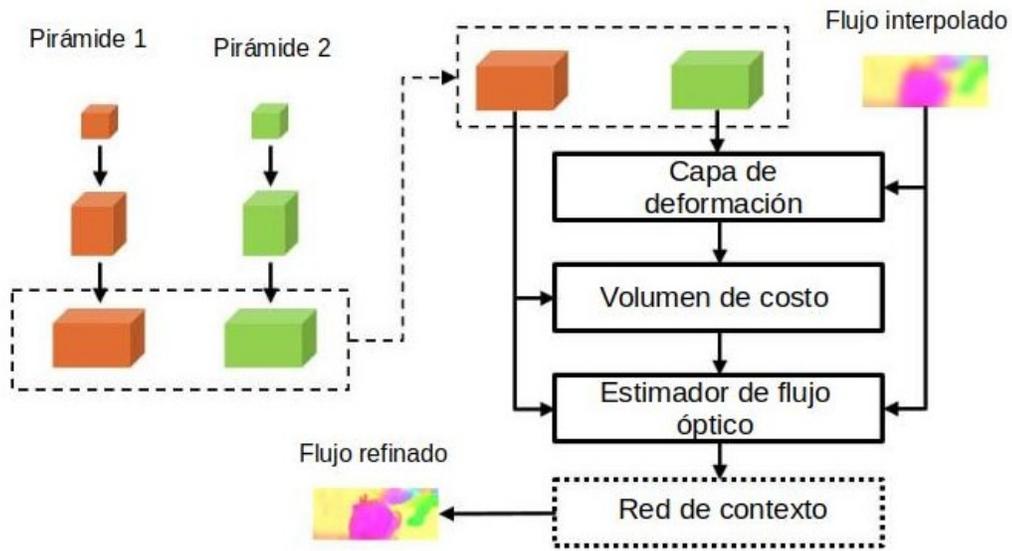


Figura 1.1: Arquitectura de la CNN PWC-Net.

Østvik *et al.* [1] propusieron una variación de la arquitectura PWC-Net para **STE** nombrada EchoPWC-Net-us, esta propuesta incluye una capa adicional de refinamiento de la matriz de desplazamiento  $\mathbf{W}$ , refinando  $\mathbf{W}$  desde la última capa de la pirámide de características con las dimensiones más pequeñas hasta la primera capa de la pirámide, estimando así una matriz  $\mathbf{W}$  de la mitad del tamaño de las imágenes de entrada. Además, se agregan parámetros de pérdida asociados a la última interpolación para obtener una matriz del tamaño de las imágenes de entrada y se elimina la capa de deformación; los autores justifican que la capa de deformación es innecesaria porque el objetivo de esa capa es sensibilizar la red a desplazamientos grandes y en los algoritmos de **STE** los movimientos son pequeños por lo general. La red EchoPWC-Net-us fue entrenada con la misma base de datos sintética usada para la evaluación de los trabajos revisados en el estado del arte. Los autores realizaron aumento de datos, introduciendo artefactos realistas de ultrasonido a dicha base de datos. Los resultados fueron comparados con la red PWC-Net, FlowNet 2.0 y un algoritmo de flujo óptico propuesto por Farnebäck *et al.* [31]. La red EchoPWC-Net-us tuvo mejores resultados que los otros algoritmos y tuvo mayor estabilidad de error ante el aumento de datos al agregar artefactos en las secuencias de ecocardiogramas sintéticos, en promedio la red EchoPWC-Net-us obtuvo un co-

eficiente de correlación de 0.84 y el tiempo de ejecución de la red para estimar la deformación global longitudinal fue de  $18.9 \pm 0.7$  fotogramas por segundo.

A continuación, se ilustran las características más importantes de cada algoritmo revisado en el estado del arte. Estas características se ilustran en la tabla comparativa 1.1.

Tabla 1.1: Comparación de las características de todos los algoritmos de STE presentados en el estado del arte.

Algoritmo	Familia	Función de costo (FC)	Descripción	Coefficiente de correlación promedio ( $\rho$ )	Tiempo por par de fotogramas	Hardware
<b>Algoritmo Base Sintética</b> (Alesandrini <i>et al.</i> [3])	Registro elástico de imagen	Suma de diferencias al cuadrado y energía de flexión	El algoritmo parametriza el campo de desplazamiento mediante interpolación con funciones B-spline, los puntos de control son estimados optimizando la FC	0.75		
<b>BM Optimizado</b> [24]	Coincidencia de bloques (BM)	Suma de diferencias al cuadrado y discontinuidad del campo de desplazamiento	En contraste con algoritmos tradicionales de BM se optimiza la FC con un elemento de penalización obtenido al suavizar el campo mediante un filtro de medianas	0.97	10 segundos	Intel Xeon E5630
<b>AFFD</b> [23]	Registro elástico de imagen	Suma de diferencias al cuadrado, penalización de suavizado y conservación del volumen.	AFFD mapea del espacio anatómico al cartesiano, mediante el producto tensorial de funciones B-spline, usando como malla de puntos de control la segmentación del endocardio, se estima el campo de desplazamiento	0.84	10 minutos	1.8 GHz , 256 GB de RAM
<b>AAOF</b> [22]	Flujo óptico	Modelo de energía	Se extrae la superficie del VI con un algoritmo de superficies activas, se estima el campo de desplazamiento resolviendo la ecuación de flujo óptico y la FC	0.95	3.8 segundos	3.6 GHz, 4 núcleos
<b>S-Demons</b> [25]	Flujo óptico	Función de energía	Minimiza la FC sobre los puntos de interés mediante descenso de gradiente y suaviza el campo de desplazamiento estimado.	0.88	0.08 segundos	2.70 GHz, 16 GB de RAM
<b>BM</b> [2]	Coincidencia de Bloques	Correlación cruzada normalizada	El algoritmo incrementa la resolución espacial con una interpolación con funciones B-splines cúbicas, se minimizó la FC para obtener el campo de desplazamiento y posteriormente se suavizó temporalmente.	0.75	129 segundos	Intel i7, 6GB de RAM
<b>EchoPWC-Net-us</b> [1]	Flujo óptico	Correlación cruzada	Es una CNN que estima y ajusta el campo de desplazamiento a distintas escalas mediante una representación piramidal de los mapas de características	0.84	0.053 segundos	Intel Xeon E5-2637, 3.5 GHz, 112 GB de RAM

Analizando la Tabla 1.1 se puede sugerir que el algoritmo de BM Optimizado [24] es el algoritmo con el mayor valor promedio de  $\rho$  entre la deformación longitudinal estimada y la deformación longitudinal real, en los distintos segmentos de la pared del VI para los distintos equipos de ultrasonido de la base de datos sintética [3]. Los autores del algoritmo sugieren una implementación paralela para reducir el tiempo de ejecución. En general, los algoritmos basados en flujo óptico demuestran buenos resultados con un valor de  $\rho$  mayor o igual a 0.84 y con tiempos de ejecución menores o iguales a 3.8 segundos para la estimación de flujo en pares consecutivos de fotogramas. El algoritmo de STE EchoPWC-Net-us basado en CNN demostró estabilidad ante un aumento de ecocardiogramas con distinto nivel de presencia de artefactos, aunque el coeficiente de correlación  $\rho$  no esté entre los 3 primeros de la tabla comparativa 1.1.

Hasta este punto se concluye la revisión de los antecedentes, donde se hizo una comparación de los trabajos revisados, empleando como métricas el tiempo de ejecución y la correlación que existe entre las deformaciones estimadas y las deformaciones de referencia. En el trabajo realizado por Østvik *et al.* [1] encontraron que era insuficiente evaluar los algoritmos de STE con dichas métricas en condiciones ideales, por lo que propusieron evaluar la estabilidad que tienen los algoritmos de STE para estimar la deformación en registros con artefactos. En este trabajo de tesis se plantea una metodología que además de priorizar las métricas mencionadas, cuida mantener la estabilidad ante registros con ruido.

## 1.2. Planteamiento del problema

En el **capítulo** anterior se mencionó el buen rendimiento que tuvo el algoritmo de BM Optimizado, sin embargo, con base en el trabajo de Østvik *et al.* [1] se planteó la necesidad de validar los algoritmos de STE propuestos ante registros con artefactos resultantes del proceso de adquisición. En ecocardiogramas transtorácicos 2D la inconsistencia de brillo y las oclusiones pueden ser causadas por el ruido acústico (también conocido como ruido *speckle*), por el movimiento de la cavidad cardíaca fuera del plano de adquisición, sombreados acústicos y por la deformación de la cavidad (debido movimientos de compresión, expansión, corte o ro-

tación) [26]. En este trabajo se busca desarrollar una nueva metodología de **STE**, basada en el trabajo realizado por Østvik *et al.* [1], que utilice una arquitectura de aprendizaje profundo que sea capaz de mitigar dichos artefactos que son naturales de los registros de ultrasonido. De esta manera se busca que el algoritmo de **STE** propuesto mejore o iguale el rendimiento de los algoritmos revisados en el estado del arte y que sea estable ante registros ruidosos.

### 1.3. Justificación

Para la evaluación del funcionamiento del corazón se ha propuesto la cuantificación de distintos índices, de los cuales los índices más útiles aunque no los más utilizados son los obtenidos mediante el análisis de deformación [17], en específico el índice de GLS que ha demostrado ser un fuerte predictor para distintas patologías cardíacas, en especial cuando la FE permanece preservada [18, 32]. En ese sentido, en este trabajo se desarrolla un algoritmo de **STE** para la estimación de índices de deformación. Dado que se busca que el algoritmo de **STE** sea estable ante artefactos, se trabajará con algoritmos basados en aprendizaje profundo, los cuales han demostrado tener dicha estabilidad [1]. A diferencia del algoritmo PWC-Net-us, en este trabajo se hizo uso de una arquitectura que fue diseñada para tratar los problemas de flujo óptico, como lo son la inconsistencia de brillo y las oclusiones. Ésto con el objetivo de tener un algoritmo de **STE** que sea capaz de estimar los indicadores de deformación como el índice de GLS, y, que éste sea estable ante registros ruidosos.

### 1.4. Hipótesis

Al implementar un algoritmo de **STE** utilizando una arquitectura de aprendizaje profundo, que se especialice en la estimación de flujo en registros con inconsistencia de brillo y oclusiones, se espera que mejore o iguale las figuras de mérito de los algoritmos revisados en el estado del arte y que sea estable ante registros ruidosos. Permitiendo así estimar los indicadores de deformación como el índice de GLS y que no haya diferencia significativa en la estimación de

éste índice en registros con y sin artefactos.

## 1.5. Objetivos

### 1.5.1. Objetivo General

Desarrollar y validar un algoritmo de **STE** usando una arquitectura de aprendizaje profundo de flujo óptico, especializada en registros con oclusiones e inconsistencia de brillo, que sea capaz de estimar la deformación en las paredes del ventrículo izquierdo usando ecocardiogramas 2D de manera confiable, reproducible y estable, con figuras de mérito mejores o iguales que las reportadas en el estado del arte y con un índice de GLS, cuyo error es menor a una referencia y es estable ante registros ruidosos.

### 1.5.2. Objetivos Específicos

- Diseñar una metodología de **STE** basada en una arquitectura de aprendizaje profundo capaz de tratar con registros con artefactos de oclusiones e inconsistencia de brillo.
- Establecer las bases de datos necesarias para la metodología propuesta.
- Evaluar la metodología propuesta con la base de datos y las figuras de mérito usadas en el estado del arte para valorar el rendimiento de los algoritmos de **STE**.
- Evaluar el error entre la deformación estimada y real de una base de datos sintética aumentada con artefactos sintéticos y sin aumento, para valorar la estabilidad de la metodología propuesta ante registros ruidosos.

# Capítulo 2

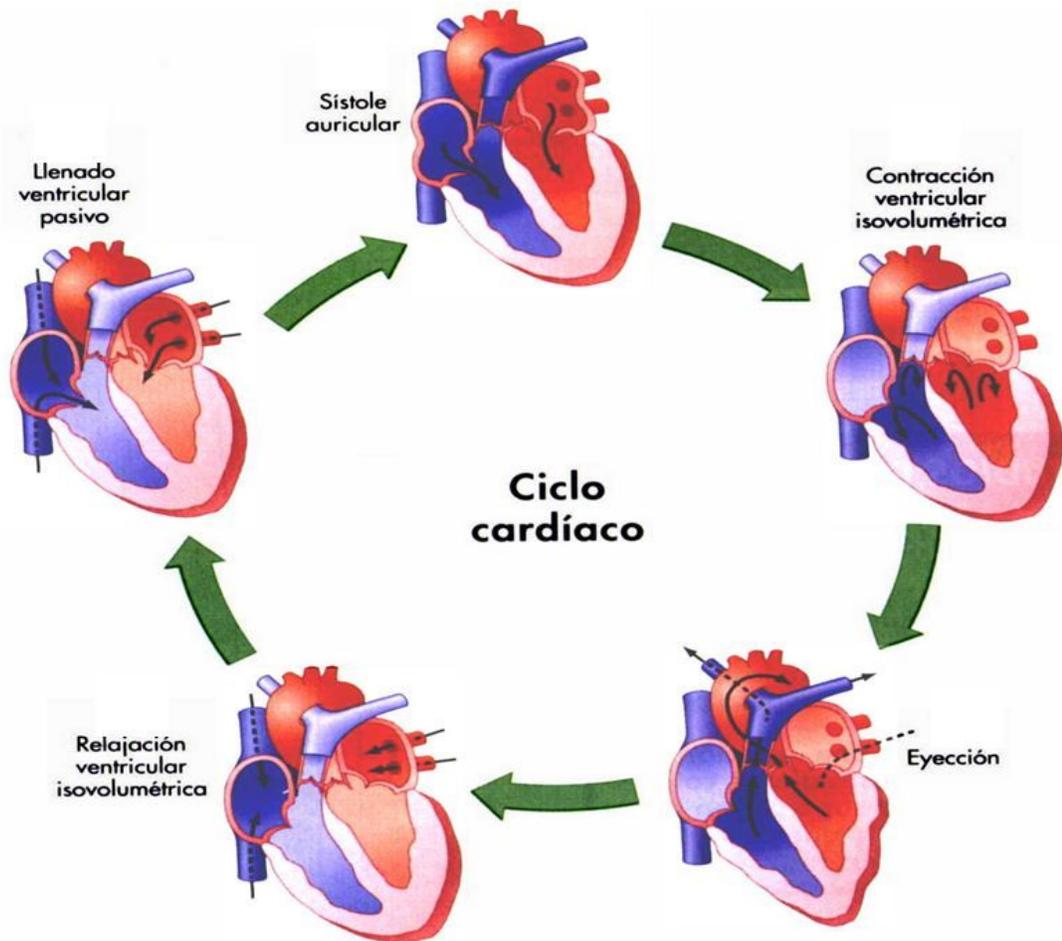
## Marco Teórico

### 2.1. Anatomía, fisiología y patologías del corazón

#### 2.1.1. Ciclo cardíaco

El corazón es una estructura con 4 cámaras: aurícula izquierda (AI), aurícula derecha (AD), ventrículo izquierdo (VI) y ventrículo derecho (VD). Dicha estructura, funcionalmente puede verse como 2 bombas acopladas en serie; las cámaras derechas que bombean la sangre de las venas hacia el sistema circulatorio pulmonar para oxigenar la sangre y las cámaras izquierdas que bombean la sangre oxigenada hacia la circulación sistémica por medio de la arteria aorta [4]. El corazón repite periódicamente un ciclo cardíaco, el cual está compuesto de 2 fases: la diástole y la sístole. La diástole es en la cual la sangre regresa al corazón por medio de las venas cavas hacia la AD de manera pasiva (músculos relajados), cuándo la diferencia de presión entre la AD y el VD es positiva, la válvula que conecta ambas cámaras (tricúspide) se abre, llenándose de manera pasiva el VD; al mismo tiempo las cámaras izquierdas realizan un mecanismo similar para llenar pasivamente ambas cámaras de sangre oxigenada proveniente de la circulación pulmonar. En la fase de la sístole, a diferencia de la diástole los músculos se contraen (activo), inicialmente en dicha fase se realiza el llenado activo de los ventrículos con la contracción de sus respectivas aurículas, conforme la diferencia de presión entre las aurículas y los ventrículos disminuye las válvulas que conectan las cámaras (tricúspide y mitral) se cierran; después los ventrículos se contraen mientras las válvulas aórtica y pulmonar están

cerradas, incrementando la presión en dichas cámaras y sin cambios de volumen, conforme la diferencia de presión entre los ventrículos y las arterias incrementa sus respectivas válvulas se abren, finalmente eyectando la sangre por ambas arterias al contraerse ambos ventrículos. El ciclo cardíaco se ilustra en la Figura 2.1.

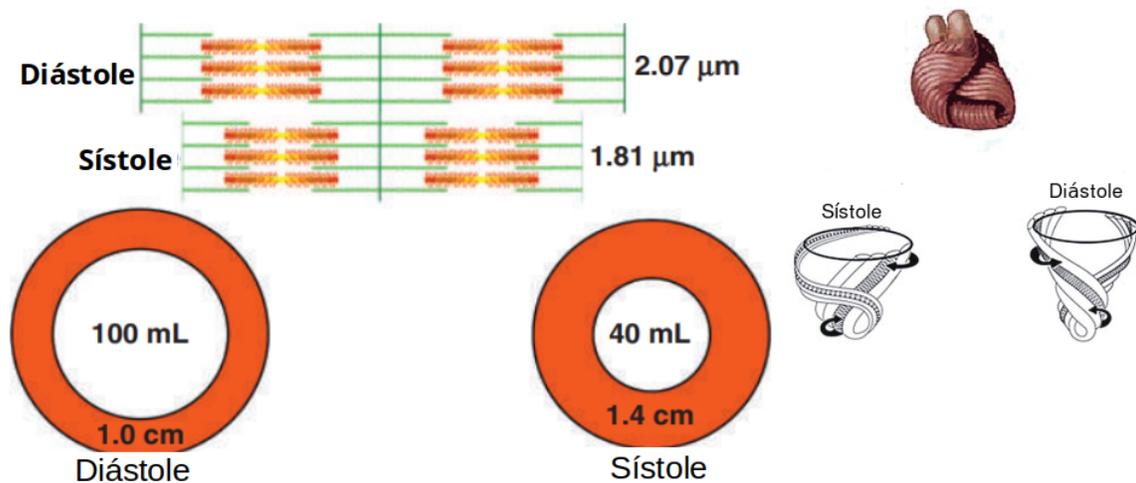


**Figura 2.1:** El ciclo cardíaco empieza con la sístole auricular, después con la sístole ventricular, luego con la diástole auricular y finalmente con la diástole ventricular, Figura modificada y tomada de [4].

### 2.1.2. Anatomía funcional del ventrículo izquierdo

La principal tarea del VI es eyectar la sangre oxigenada a la circulación sistémica por medio de la arteria aorta. El VI es una capa muscular hueca, capaz de eyectar más del 60 % del volumen en el final de la diástole (100 mL) cuando se contrae el músculo cardíaco del ven-

trículo izquierdo. La capacidad contráctil se atribuye a unas unidades microanatómicas de las células musculares del tejido cardíaco conocidas como sarcómeros, que son capaces de acortarse solamente un 13 %, que se traduce en un acortamiento longitudinal y circunferencial de 20 %, así como un engrosamiento radial de 40 %. La capacidad de eyección del VI se atribuye mayormente a la distribución de las fibras musculares; donde, en la capa más externa de tejido cardíaco (epicardio), las fibras están dispuestas en una doble hélice orientada a la izquierda y como una doble hélice orientada a la derecha en la capa más interna de tejido cardíaco (endocardio) [5]. Lo anterior se ilustra en la Figura 2.2.



**Figura 2.2:** En esta figura se ilustra un acortamiento de los sarcómeros de alrededor del 13 %, resultando en una fracción de eyección del VI del 60 %, lo anterior se atribuye a el arreglo de fibras en forma de doble hélice [5].

Después del breve abordaje de la fisiología y anatomía cardíaca, se describen en la siguiente sección algunas de las patologías cardíacas más importantes que afectan el tejido del músculo cardíaco.

### 2.1.3. Enfermedad Coronaria

La enfermedad coronaria es una cardiopatía dada por el estrechamiento de las arterias coronarias que suministran sangre al músculo cardíaco. Dicho estrechamiento puede estar da-

do por un coágulo de sangre, por la constricción de los vasos sanguíneos, o de manera más frecuente, es causado por la acumulación de placa de ateroma (grasas, colesterol y otras sustancias) en las paredes de las arterias; cuando la oclusión de las arterias es total ocurre un infarto del miocardio en el que se mueren células del músculo cardíaco [33].

#### **2.1.4. Cardiomiopatía Diabética**

La cardiomiopatía diabética es una de las etiologías frecuentes en pacientes con diabetes tipo 1 y tipo 2. Dicha enfermedad tiene como consecuencia alteraciones a nivel molecular, metabólico, mitocondrial, celular y tisular del músculo cardíaco, generalmente asociadas a hiperglicemia, hiperinsulinemia, lipotoxicidad por ácidos grasos libres y resistencia a la insulina. Esta enfermedad puede ser asintomática durante años, sin embargo puede disparar afectaciones como insuficiencia cardíaca, muerte súbita y muerte cardiovascular [34].

#### **2.1.5. Enfermedad Valvular**

Cuando la válvula aórtica se vuelve progresivamente estrecha (estenótica) se aumenta el gradiente de presión entre el VI y la aorta. Por lo tanto, el gasto cardíaco se ve reducido y eventualmente induce hipertrofia ventricular izquierda e insuficiencia cardíaca [35]. El estrechamiento del área valvular es debido a un proceso de calcificación en la válvula aórtica, posiblemente como consecuencia de una actividad proinflamatoria no regulada correctamente.

#### **2.1.6. Enfermedades Pericárdicas**

Pericarditis es un término empleado para indicar cuando ocurre una inflamación de la membrana que recubre el corazón (pericardio) debido a una infección aguda (viral, bacteriana o parasitaria), irradiación o enfermedad autoinmune (lupus sistémica, enfermedad de Still, artritis reumatoide, entre otras.) [36].

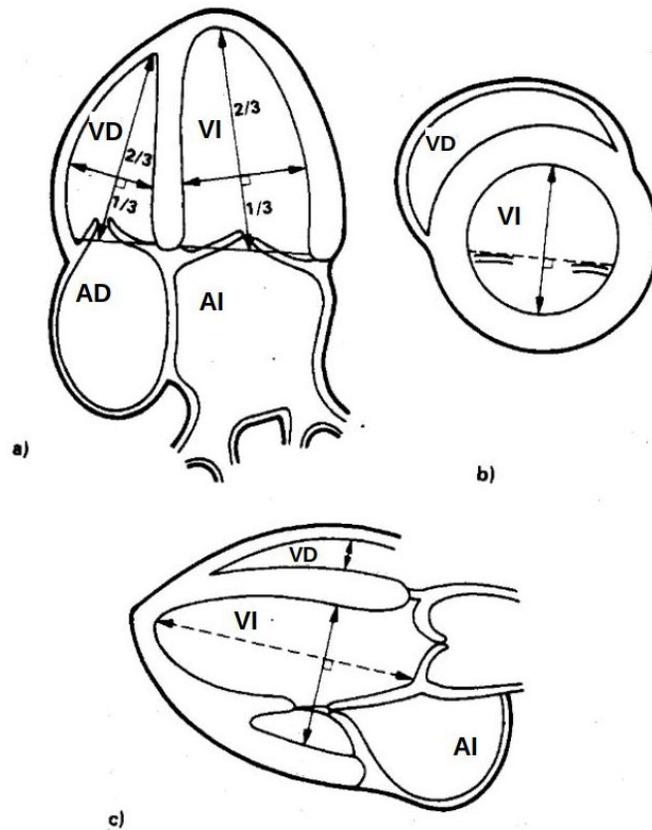
Una enfermedad parasitaria que causa pericarditis se conoce como Chagas, esta enfermedad es causada por el parásito protozooario *Trypanosoma cruzi*, éste es transportado principalmente por el vector triatomino de la familia Reduviidae, orden Hemiptera, también conocido como “chinche besucona”. El vector deposita los parásitos por medio de las heces y éstos penetran en el cuerpo cuando la persona se rasca y con el barrido mecánico desplaza los parásitos hacia la herida de la picadura, alguna otra herida, boca o incluso los ojos. La enfermedad del Chagas tiene dos fases: la primera es la fase aguda, la cual tiene una duración de 2 a 8 semanas, y solo el 5 % de los pacientes presentan síntomas; y la siguiente etapa de la enfermedad se conoce como la etapa crónica, la cual puede ser determinada o indeterminada. La fase indeterminada se presenta en un intervalo de 4 a 10 semanas después de la infección, esta fase se caracteriza por ser la fase crónica asintomática, la transición entre la fase crónica indeterminada y la fase crónica determinada puede durar hasta más de 30 años [37]. El 30 % de los pacientes con Chagas presentan su fase crónica determinada con afecciones cardíacas; como el mal funcionamiento del sistema de conducción eléctrico del corazón, arritmias cardíacas, miocardiopatía dilatada e insuficiencia cardíaca. También, los pacientes pueden presentar su fase crónica determinada con afecciones digestivas y afecciones digestivas y cardíacas [38].

## 2.2. Índices de función cardíaca

Como se vió en la sección anterior, las cámaras cardíacas están formadas por el tejido cardíaco llamado miocardio y en total son 2 aurículas y 2 ventrículos, la relajación y contracción de dichas cámaras es un proceso complejo que depende de la contractilidad, condiciones hemodinámicas, suministro de oxígeno, electrofisiología del miocardio, el pericardio y el funcionamiento de las válvulas cardíacas. Alguna afectación a cualquiera de los elementos mencionados puede resultar en anomalías en el tamaño de las cámaras, movimiento de las paredes de las cámaras, grosor de las paredes de las cámaras y/o fracción de eyección (FE) de la cámara. Por consiguiente, para la evaluación del correcto funcionamiento del ciclo cardíaco distintos autores han propuesto índices para la detección y cuantificación de dichas anomalías [17]. A continuación, se presentarán algunos de estos índices para la evaluación del VI.

### 2.2.1. Tamaño del VI

Para la correcta medición del tamaño del VI, la Asociación Americana de Ecocardiografía (ASE, por sus siglas en inglés) recomienda evaluar el tamaño del VI en el plano del eje largo (desde el ápice del VI hasta la válvula mitral) y en el eje corto paraesternal. Las mediciones en el eje largo y eje corto del eje paraesternal pueden ser vistos como el eje mayor y el eje menor de una elipse alargada con un ápice cónico, respectivamente. Ésto para la estimación del área y volumen del VI en un corazón sano [17]. En la Figura 2.4 se visualiza la medición del tamaño del VI desde distintos planos o vistas, estos planos o vistas serán revisados en la siguiente sección a detalle.



**Figura 2.3:** Medición del tamaño del ventrículo izquierdo desde diferentes vistas: (a) apical de 4 cámaras, (b) eje corto paraesternal y (c) eje largo paesternal [6].

### 2.2.2. Fracción de eyección del VI

El índice más utilizado en la práctica clínica para la evaluación de la función ventricular global es la FE, la mayoría de los abordajes para la estimación de la FE proponen distintas hipótesis de la geometría de la forma de la cavidad. En un primer abordaje lineal se plantea que la FE puede ser estimada con la siguiente expresión.

$$FE = \frac{V_{FD} - V_{FS}}{V_{FD}}, \quad (2.1)$$

donde  $V_{FD}$  y  $V_{FS}$  son los volúmenes del VI en el final de la diástole y en el final de la sístole, respectivamente. Distintas propuestas para la estimación del volumen se han desarrollado como la suma ponderada de volúmenes de discos elipsoidales o la suposición de que la cavidad tiene forma de bala, dichas propuestas son certeras si se realizan en la vista apical de 4 cámaras o de 2 cámaras, sin embargo, estas propuestas tienen limitaciones en presencia de anomalías en el movimiento de las paredes cardíacas del VI [17].

### 2.2.3. Análisis de deformación

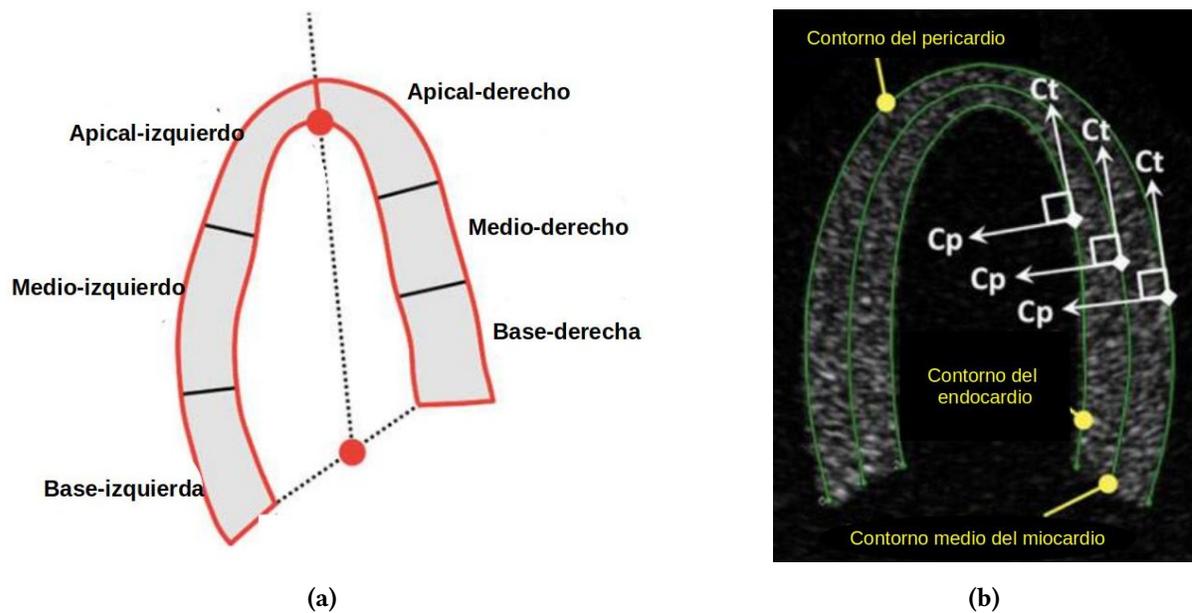
Para realizar el análisis de deformación se ha estandarizado el uso de la deformación lagrangiana ( $S_L$ ) [7]. La cual es una métrica que evalúa el cambio relativo de forma y tamaño de un objeto respecto a su forma original (objeto en el tiempo cero). La  $S_L$  unidimensional se calcula mediante el cambio relativo de longitud del objeto en una cierta componente respecto a la longitud original del objeto en dicha componente. En la ecuación 2.2 se establece el caso unidimensional de  $S_L$  en un instante  $t$ .

$$S_L(t) = \frac{L(t) - L_0}{L_0}, \quad (2.2)$$

donde  $L(t)$  es la longitud del objeto en una cierta componente (longitudinal o radial) en el instante  $t$  y  $L_0$  es la longitud del objeto en la misma componente en el tiempo inicial ( $t = 0$ ).

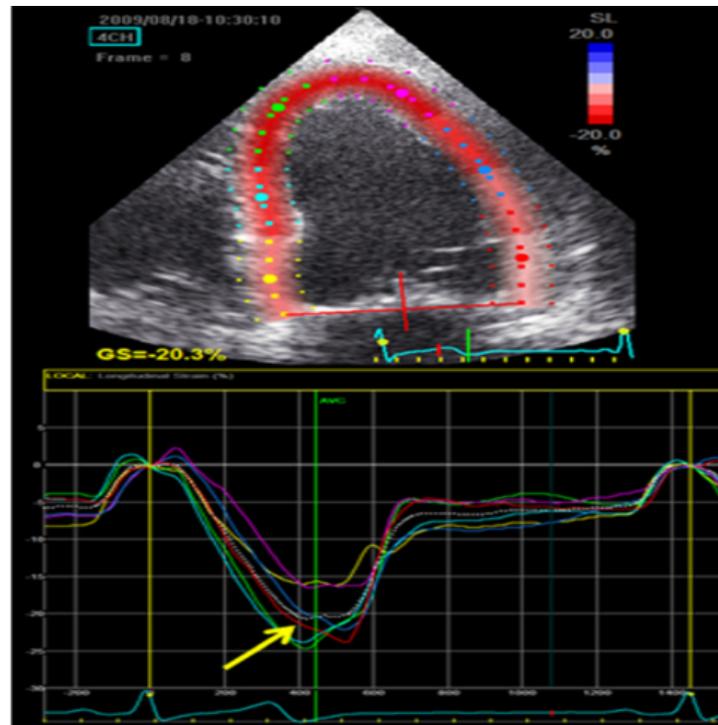
El análisis de deformación se ha estandarizado sobre ciertos segmentos de las paredes del VI [7], dichos segmentos se aprecian en el inciso a) de la Figura 2.4. El análisis de deformación

consiste en obtener  $S_L(t)$  para cada fotograma, ésto sobre los distintos segmentos de las paredes del ventrículo izquierdo, en la componente longitudinal (a lo largo de la pared cardíaca) y en la componente radial (componente ortogonal a la componente longitudinal), lo anterior se calcula para los distintos contornos (endocardio, centro y epicardio) de las paredes cardíacas y se promedia para cada segmento. En la Figura 2.4 se ilustran dichas componentes y los contornos mencionados.



**Figura 2.4:** En el inciso (a) se ilustran los distintos segmentos sobre los que se evalúa la deformación en las paredes del ventrículo izquierdo [7]. En el inciso (b) se aprecian los distintos contornos sobre los que se estima la deformación en la componente radial ( $C_p$ ) y longitudinal ( $C_t$ ) en un ecocardiograma 2D.

Como resultado de realizar el análisis de deformación de las paredes del VI sobre un ecocardiograma 2D se obtiene una curva de deformación a lo largo de la secuencia de fotogramas para cada segmento, de estas curvas se puede obtener el mínimo valor de la curva promedio para estimar un importante índice de función global del VI conocido como deformación longitudinal global (GLS, por sus siglas en inglés). En la Figura 2.5 se ilustran las curvas de deformación por segmentos, la curva promedio y el índice de GLS [8].



**Figura 2.5:** En esta figura se aprecia un ejemplo de los resultados obtenidos mediante STE en un ecocardiograma 2D. La parte de arriba de la figura se aprecia una malla de puntos clave sobre los cuales se hace el seguimiento y se estima la deformación por segmento. En la parte de abajo se presentan las distintas curvas de deformación para cada segmento, donde cada segmento tiene un color asociado [8].

La estimación de las longitudes de los segmentos en cada fotograma se obtienen a partir de un arreglo o malla de puntos clave por cada segmento, de los cuales se realiza el seguimiento fotograma a fotograma mediante un algoritmo STE. En la Figura 2.5 se aprecian estos puntos clave y las curvas de deformación con diferentes colores dependiendo del segmento.

A continuación, se hablará del impacto que tienen los índices obtenidos a partir del análisis de deformación por STE, en especial la deformación longitudinal, para la predicción de distintas patologías en la etapa subclínica cuando otros índices como la FE se mantienen preservados. La primera patología revisada es la enfermedad coronaria, en la cual la deformación longitudinal es un fuerte predictor para pacientes asintomáticos sin anomalías en el movimiento de las paredes cardíacas [18].

En un trabajo acerca de la cardiomiopatía diabética se estimó la deformación torsional

(ecocardiograma 3D) en pacientes con diabetes tipo 1 con retinopatía positiva, pacientes con diabetes tipo 1 con retinopatía negativa y sujetos sanos, se encontró que el valor más alto de deformación se presentó en el grupo con retinopatía positiva, seguido del grupo con retinopatía negativa y finalmente el grupo sano. El estudio concluye que el aumento en la deformación torsional es atribuido a la enfermedad microvascular del miocardio [19].

En un trabajo de enfermedad valvular se propuso el análisis de deformación mediante **STE** para la detección temprana de la enfermedad, debido a que se ha encontrado que en pacientes con estenosis la deformación longitudinal es reducida de manera significativa mientras que la deformación en otros ejes y la FE se mantiene preservada [18].

Finalmente, como última revisión se encontró que pacientes con la enfermedad de Chagas en etapa temprana desarrollaban movimiento anormal de las paredes del VI, principalmente en los segmentos inferior basal e inferolateral, además de disfunción diastólica [20]. Concluyendo tener diferencias significativas en el GLS entre pacientes asintomáticos en la etapa no determinada y sujetos control [21, 39, 40].

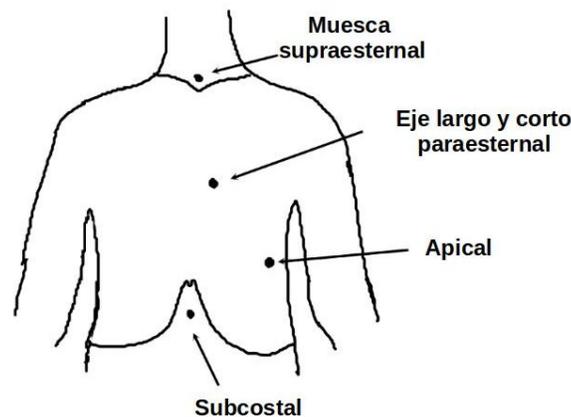
## **2.3. Técnicas de imagenología para el análisis de deformación**

En esta sección se mencionarán algunas de las técnicas no invasivas de imagenología que se usan en el área clínica para la evaluación de la deformación del tejido del músculo cardiaco en las paredes del VI.

### **2.3.1. Ecocardiografía**

Se le denomina ecocardiograma a la técnica en la que se inducen ondas ultrasónicas mediante un transductor, usualmente dichas ondas son del orden de 2 hasta 5 MHz en humanos adultos [41]. Estas ondas son absorbidas o reflejadas en los tejidos y cavidades del corazón, las

ondas reflejadas son detectadas por el transductor a distinta frecuencia de la emitida, la forma en que se codifican las señales medidas por el transductor determina los distintos modos de ultrasonido, estos modos son capaces de explorar perfiles de velocidades del flujo sanguíneo y/o estructuras de las cavidades. El ecocardiograma transtorácico (TTE, por sus siglas en inglés) 2D es realizado a través de distintas ventanas de exploración en el pecho (paraesternal, muesca supraesternal, subcostal y apical), las cuales se ilustran en la Figura 2.6. Éste es el estudio de imagenología no invasivo y no ionizante más empleado debido a sus características de inocuidad, factibilidad y reproducibilidad [41].



**Figura 2.6:** Diagrama del pecho humano ilustrando el posicionamiento de los transductores en las ventanas de exploración estándar del TTE [9].

De cada ventana estándar de la Figura 2.6 se pueden derivar distintos planos o vistas, por ejemplo de la ventana apical puede derivarse la vista apical de 4 cámaras, de 3 cámaras y de 2 cámaras (A4C, A3C y A2C, respectivamente) rotando el transductor posicionado en la ventana apical  $0^\circ$ ,  $60^\circ$  y  $90^\circ$ , respectivamente. Lo mismo sucede para la derivación de los planos o vistas de eje largo y corto en la ventana paraesternal [9].

Actualmente, se considera que el algoritmo de **STE** es la técnica clínicamente más útil para la obtención de la deformación longitudinal de las paredes cardíacas desde los distintos planos de la vista apical en ecocardiogramas bidimensionales (modo B) [18].

Existen otras técnicas para medir deformación de las paredes cardíacas como la Ecocardiografía Doppler Tisular (TDE, por sus siglas en inglés), para esta técnica se necesita una adquisición de ultrasonido en modo doppler pulsátil, midiendo así el perfil de velocidades del tejido en movimiento. Para medir un perfil de velocidades tan bajo como el de las paredes cardíacas, es necesario reducir la ganancia del equipo y enfocarse en las componentes de baja frecuencia de la señal [42].

Las ventajas que tiene **STE** sobre TDE son que es angularmente independiente, que puede medir deformación en un mayor número de ejes (longitudinal, radial y circunferencial), cuenta con confiabilidad interobservador e intraobservador, el tiempo de la técnica es menor y ha sido validado con resonancia magnética cardíaca, la cual es una técnica de imagenología que será explicada a detalle más adelante. Por otro lado, el método de TDE tiene como ventaja contar con mayor resolución temporal, teniendo como frecuencia óptima 100 fotogramas por segundo, mientras **STE** cuenta con 60 fotogramas por segundo [32].

### 2.3.2. Resonancia Magnética Cardíaca

La resonancia magnética cardíaca (CMR, por sus siglas en inglés) es una técnica de imagenología cardíaca que basa su funcionamiento en la inducción de un campo magnético, que en aplicaciones clínicas se encuentra dentro de un intervalo de 0.5 y 3 Tesla. Donde distintos átomos (principalmente hidrógeno) son estimulados y consecuentemente emiten ondas de radiofrecuencia que son detectadas por una antena para la reconstrucción de la imagen, esta modalidad es no ionizante y es segura en pacientes que no tienen en su cuerpo ningún elemento metálico como marcapasos y prótesis.

CMR se ha convertido en el estándar de oro para la evaluación de tejido cardíaco, en contraste con la técnica de **STE** para la evaluación de deformación, en CMR las técnicas de seguimiento de características (CMR-FT) para la evaluación de deformación tienen un reto menor al contar con imágenes de mayor resolución, además de que es de las modalidades más reproducibles y confiables. Los algoritmos implementados para CMR-FT además tienen un tiempo

de ejecución menor por la reducción en las etapas de preprocesamiento y postprocesamiento [43]. Actualmente, no se realiza el análisis de deformación mediante CMR-FT en la clínica a nivel mundial debido a los inconvenientes prácticos, que limitan su aplicación generalizada a la población (protocolos de escaneo complejos, tiempo de exploración prolongado, mayor gasto y contraindicado en pacientes con dispositivos intracardíacos.) [43].

### 2.3.3. Tomografía Computarizada

La tomografía computarizada cardíaca (CCT, por sus siglas en inglés) también es una técnica de imagenología, en la cual se emite un haz de rayos X a través del pecho del paciente y la radiación proyectada es detectada después de interactuar con el paciente. La señal es digitalizada, procesada y transmitida por detectores a una computadora. En esta técnica de imagenología se construye una imagen estructural tridimensional del corazón. Actualmente, aunque no se utiliza esta técnica de imagenología en la clínica para el análisis de deformación, se han hecho grandes avances de investigación para la implementación de análisis de deformación mediante algoritmos de seguimiento de tejido multimodal, que basan su funcionamiento en algoritmos de STE [15].

Para concluir esta sección se ilustra en la Tabla 2.1 las principales diferencias entre las distintas técnicas de imagenología que se emplean para el análisis de deformación.

**Tabla 2.1:** Comparación entre las distintas técnicas de imagenología [15].

	CMR	TTE	CCT
<b>Resolución espacial</b>	1-2 mm	<1mm	0.35- 0.5 mm
<b>Resolución temporal</b>	25-50 ms	10-25 ms	83- 175 ms
<b>Tiempo de adquisición</b>	30-45 min	30 min	10 min

A partir de la Tabla 2.1 y la revisión realizada en esta sección, se concluye que la técnica de imagenología más adecuada para este estudio es el TTE debido a que tiene una mayor resolución temporal, la cual es una característica que facilita el seguimiento en el algoritmo de STE,

además es una técnica no ionizante y puede ser realizada en pacientes que tengan elementos metálicos dentro del cuerpo, éstas son algunas de las ventajas que ofrece esta técnica.

## 2.4. Aprendizaje profundo

El aprendizaje profundo es un conjunto de métodos de aprendizaje que intentan aproximar una función mediante el uso de arquitecturas complejas de redes neuronales artificiales (ANN, por sus siglas en inglés), donde ANN es una red interconectada de nodos inspirada en las redes neuronales biológicas. En la Figura 2.7 se aprecia una arquitectura para una ANN de una capa y cuando se propaga hacia adelante una entrada  $\mathbf{x} = (x_1, \dots, x_n)$  resulta en una salida dada por la siguiente expresión:

$$\hat{y} = \phi(\mathbf{x}^T \mathbf{w} + b), \quad (2.3)$$

donde  $\hat{y}$  es la salida estimada en la propagación hacia adelante,  $\phi$  es la función de activación,  $\mathbf{w} = (w_1, \dots, w_n)$  es el vector de pesos y  $b$  es el sesgo de la neurona. Existen distintas funciones de activación, por nombrar algunas se tiene la identidad ( $\phi(x) = x$ ), la unidad lineal rectificada (ReLU) que está dada por  $\phi(x) = \max(0, x)$  y la función sigmoide que puede ser expresada como  $\phi(x) = \frac{1}{1+e^{-x}}$  [44].

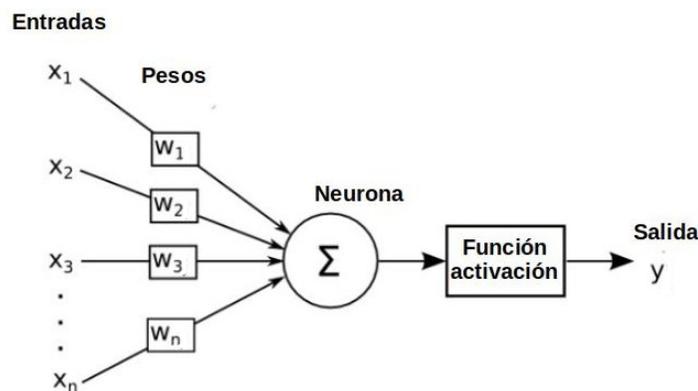


Figura 2.7: Red neuronal artificial de una capa.

Para que este modelo de aprendizaje inspirado en la neurona aprenda es necesario optimi-

zar sus pesos para distintas entradas, el optimizador más empleado es el descenso del gradiente. En el descenso del gradiente se utiliza como regla de actualización de pesos la siguiente ecuación, donde se revisa el caso en el que la función de activación es la identidad y la función de costo  $f$  a optimizar es el error cuadrático:

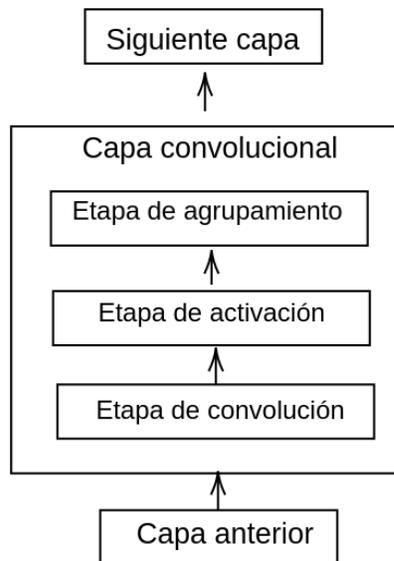
$$\begin{aligned}
 \mathbf{w}^{(t+1)} &= \mathbf{w}^{(t)} - \eta \nabla f \\
 \mathbf{w}^{(t+1)} &= \mathbf{w}^{(t)} - \eta \frac{\partial (y - \hat{y})^2}{\partial \mathbf{w}^{(t)}} \\
 \mathbf{w}^{(t+1)} &= \mathbf{w}^{(t)} + \eta (y - \hat{y}) \frac{\partial \phi(\mathbf{x}^T \mathbf{w}^{(t)} + b)}{\partial \mathbf{w}^{(t)}} \\
 \mathbf{w}^{(t+1)} &= \mathbf{w}^{(t)} + \eta (y - \hat{y}) \mathbf{x},
 \end{aligned} \tag{2.4}$$

donde  $\eta$  es la tasa de aprendizaje, el cuál sería el hiperparámetro a regular del optimizador,  $w$  tiene superíndices que indican la iteración a la que corresponde y  $y$  es la salida objetivo. Cuando se tiene una ANN con muchas capas de neuronas intermedias entre la salida y la entrada se dice que se tiene una ANN profunda, en este tipo de redes el gradiente entre la entrada y salida no es inmediato ya que existen distintas capas intermedias, para obtener dicho gradiente es necesario aplicar la regla de la cadena sobre dichas capas intermedias.

### 2.4.1. Redes Neuronales Convolucionales

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son aquellas ANN profundas que están compuestas por arquitecturas complejas en las que su elemento base es un bloque convolucional. Estos bloques fueron inspirados en la corteza visual primaria de los mamíferos, la cual es la primera área cerebral que de manera significativa realiza un procesamiento avanzado a la entrada visual del mamífero. Estos bloques tienen 3 principales características inspiradas en la corteza visual primaria, que son traducidas a 3 distintas capas que compone dicho bloque: a) las unidades de aprendizaje (pesos) son distribuidas espacialmente en mapas conocidos como mapas de características que convolucionan espacialmente con la entrada del bloque convolucional, b) emular la respuesta de una célula excitable simple ante varias entradas espacialmente distribuidas con las funciones de activación y por último, c) emular células complejas que responden ante entradas similares a las de las células simples

pero tienen la diferencia de que son invariantes ante pequeños corrimientos de las entradas, estas células complejas pueden ser modeladas con el uso de capas de agrupamiento. Estas tres capas integran el bloque convolucional, en la Figura 2.8 se ilustra dicha integración de las capas [10].



**Figura 2.8:** Bloque convolucional como unidad base de las CNN.

Las CNN se especializan principalmente en resolver problemas de visión computacional dada la naturaleza con la que trabaja los valores de la entrada espacialmente distribuidos como estructura de rejilla, lo cual se adapta muy bien a datos con esa estructura como lo son las imágenes.

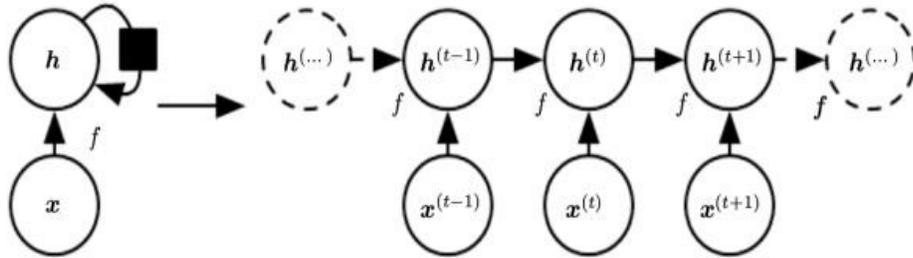
### 2.4.2. Redes Neuronales Recurrentes

Las redes neuronales recurrentes (RNN, por sus siglas en inglés) son una familia de las ANN que se especializan en procesar entradas secuenciales de la forma  $\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(\tau)}$  para aproximar una función que involucre alguna recurrencia, por ello son principalmente usadas en problemas de procesamiento del lenguaje natural.

Las RNN tienen como unidad base una unidad oculta ( $\mathbf{h}^{(t)}$ ) la cual representa el estado del sistema en un cierto instante, en estas unidades es donde ocurre la recurrencia a través de una función como la siguiente:

$$\mathbf{h}^{(t)} = f(\mathbf{h}^{(t-1)}, \mathbf{x}^{(t)}; \theta), \quad (2.5)$$

donde  $\mathbf{x}^{(t)}$  es una cierta entrada en ese instante y  $\theta$  representa los elementos de la red que parametrizan la función, una de las principales características de las RNN es que estos parámetros se comparten en el sistema a través del tiempo. La expresión anterior puede ser representada mediante un grafo cíclico dirigido como el de la parte izquierda de la Figura 2.9 donde la recurrencia actúa sobre la unidad oculta, así mismo este grafo se puede representar de manera acíclica haciendo explícita la recurrencia sobre  $\mathbf{h}^{(t)}$ , como se muestra en la parte derecha de la Figura 2.9.



**Figura 2.9:** RNN sin salidas, donde se hace explícita la recurrencia sobre la unidad oculta  $\mathbf{h}$  en cada instante de tiempo mediante una función  $f$ , este grafo representa la ecuación 2.5 [10].

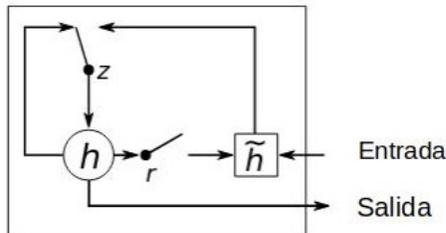
La función de recurrencia de la ecuación 2.5 puede estar dada por la siguiente expresión:

$$\mathbf{h}^{(t)} = \phi(\mathbf{b} + \mathbf{W}\mathbf{h}^{(t-1)} + \mathbf{U}\mathbf{x}^{(t)}), \quad (2.6)$$

donde los parámetros  $\mathbf{W}$  y  $\mathbf{U}$  son matrices de pesos y  $\mathbf{b}$  es el sesgo. Si expandimos la función de recurrencia de la ecuación anterior hasta el tiempo inicial queda de la siguiente manera:

$$\mathbf{h}^{(t)} = \phi\left(\mathbf{W}^{(t)}\mathbf{h}^{(0)} + \sum_{t_0=1}^t \mathbf{W}^{(t_0-1)}\mathbf{b} + \mathbf{W}^{(t_0-1)}\mathbf{U}\mathbf{x}^{(t_0)}\right). \quad (2.7)$$

De la ecuación 2.7 se puede apreciar que cuando se explora un vector de estado ( $\mathbf{h}^{(t)}$ ) de la unidad oculta que tiene dependencias en el tiempo de largo plazo, entonces los valores de la matriz  $\mathbf{W}$ , al elevarse a la potencia de  $t$ , pueden desvanecerse en caso de que los valores fueran menores que 1 o converger hacia el infinito en caso de que fueran mayores a 1. Este comportamiento no deseado para relaciones de recurrencia de largo plazo se puede corregir empleando unidades ocultas más complejas. Una propuesta de unidad oculta, que tiene mecanismos para tratar las dependencias de largo plazo, es la Unidad Recurrente Controlada (GRU, por sus siglas en inglés). Esta unidad cuenta con ciertas compuertas, las cuales controlan qué tanta información del estado anterior se transfiere al estado actual. Estas compuertas permiten descartar cualquier información que sea irrelevante para el futuro, para que el modelo pueda decidir qué información es relevante se asocian dichas compuertas a matrices de pesos que aprenden a guardar estas dependencias que son de utilidad [11], las expresiones de dichas matrices se pueden apreciar en la siguiente ecuación y en la Figura 2.10 se aprecia un diagrama de la GRU.



**Figura 2.10:** Diagrama de una GRU, donde  $\mathbf{z}$  es la compuerta de actualización que establece si el estado de la unidad oculta  $\mathbf{h}$  va a actualizarse con un nuevo estado  $\tilde{\mathbf{h}}$  y  $\mathbf{r}$  es la compuerta de reinicio, la cual establece si se ignoran estados de la unidad oculta del pasado [11].

La GRU cuenta con una compuerta de reinicio ( $\mathbf{r}$ ), una compuerta de actualización ( $\mathbf{z}$ ) y una unidad oculta candidata ( $\tilde{\mathbf{h}}$ ), las ecuaciones que corresponden a estos elementos se aprecian a continuación:

$$\begin{aligned}
\mathbf{r}^{(t)} &= \phi(\mathbf{b}^r + \mathbf{U}^r \mathbf{x}^{(t)} + \mathbf{W}^r \mathbf{h}^{(t)}) \\
\mathbf{z}^{(t)} &= \phi(\mathbf{b}^z + \mathbf{U}^z \mathbf{x}^{(t)} + \mathbf{W}^z \mathbf{h}^{(t)}) \\
\tilde{\mathbf{h}}^{(t)} &= \phi(\mathbf{b} + \mathbf{U} \mathbf{x}^{(t)} + \mathbf{W}^r \mathbf{h}^{(t)} \odot \mathbf{h}^{(t)}),
\end{aligned} \tag{2.8}$$

donde los superíndices de los pesos y los sesgos denotan a que compuerta corresponden dichos parámetros libres, y,  $\odot$  denota la multiplicación elemento a elemento. Finalmente, la función de la unidad GRU está dada por la siguiente función recurrente:

$$\mathbf{h}^{(t)} = \mathbf{z}^{(t-1)} \odot \mathbf{h}^{(t-1)} + (\mathbf{1} - \mathbf{z}^{(t-1)}) \odot \tilde{\mathbf{h}}^{(t-1)}. \tag{2.9}$$

## 2.5. Flujo óptico

Los algoritmos de flujo óptico son algoritmos de visión computacional que tienen como objetivo estimar el movimiento a través de una secuencia de imágenes. La mayoría de los algoritmos de flujo óptico son aplicados a 2 fotogramas, en donde se busca mapear el movimiento desde un fotograma al consecutivo, repitiendo este proceso a lo largo de la secuencia de imágenes. Existen varios problemas a resolver en el flujo óptico como las oclusiones, ruido y la inconsistencia en el brillo o el valor de los píxeles [45].

Las oclusiones de píxeles son un problema que hace imposible el proceso de mapear el movimiento en fotogramas consecutivos para esos píxeles, por lo que es necesario ubicar las oclusiones para penalizar y regularizar en esas posiciones la estimación de los vectores de desplazamiento. La consistencia en el brillo es la suposición de que un punto en un fotograma va a tener el mismo nivel de brillo en su nueva posición en el fotograma consecutivo. Matemáticamente se puede expresar con la siguiente ecuación.

$$\mathbf{I}(x, y, t) = \mathbf{I}(x + u, y + v, t + 1), \tag{2.10}$$

donde  $\mathbf{I}(x, y, t)$  es la intensidad o el brillo de la imagen para una cierta posición en el tiempo  $t$ ,  $u$  y  $v$  denotan las componentes de un vector de desplazamiento. Para tratar este problema

distintos métodos suponen que los vectores de desplazamiento deben de estar suavizados temporal y espacialmente [45].

Como se definió anteriormente los algoritmos de flujo óptico proporcionan a la salida mapas de vectores de desplazamiento, estos mapas pueden ser de 2 tipos: mapas dispersos y mapas densos. En los mapas dispersos solo se estiman los vectores de desplazamiento para ciertos puntos clave o característicos, como esquinas o bordes. Mientras en los mapas densos se estiman los vectores de desplazamiento para todos los puntos o píxeles de la imagen. En este trabajo se trabaja con algoritmos que estiman mapas de desplazamiento densos.

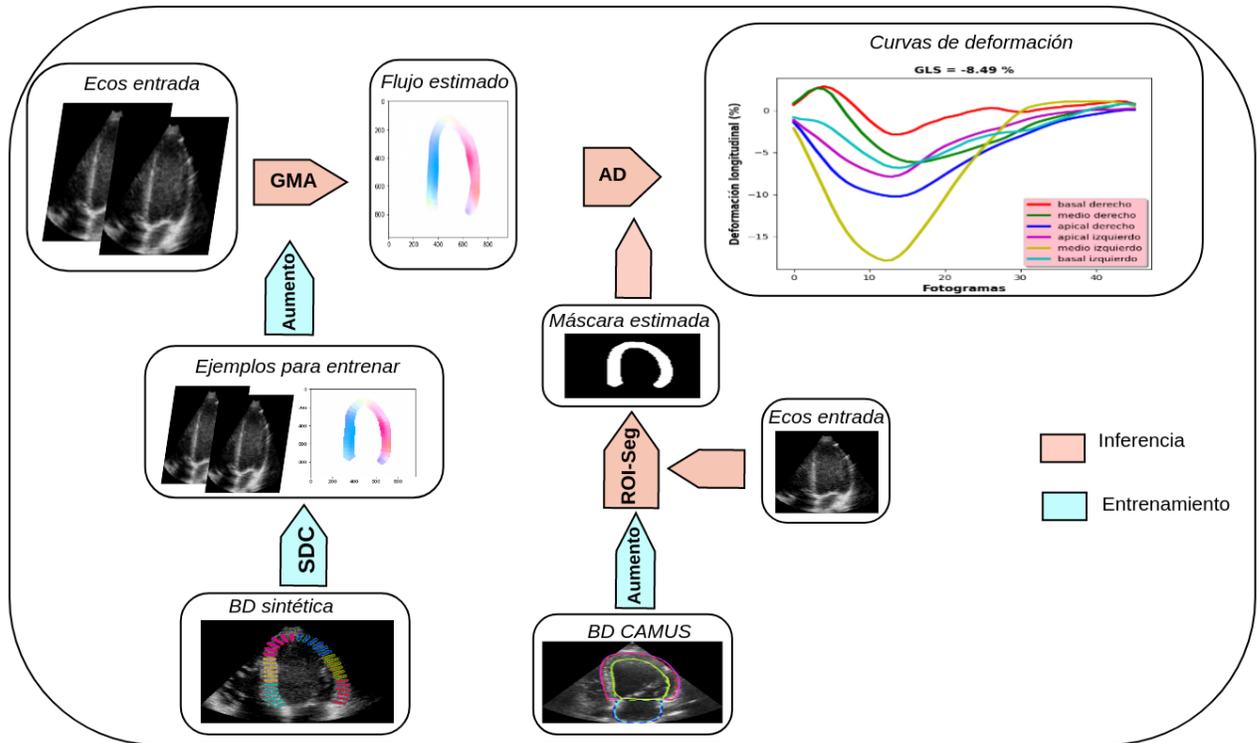
Un algoritmo que se empleó en este trabajo es el algoritmo de Farneback [31]. Este algoritmo busca aproximar un píxel y su vecindario por medio de polinomios de cierto grado en fotogramas consecutivos. Así mismo, el algoritmo representa los desplazamientos de manera parametrizada mediante una función polinomial evaluada en el plano x-y. Donde los coeficientes del polinomio son calculados resolviendo un problema de optimización de búsqueda entre vecindarios en una cierta ventana [31]. Este algoritmo se puede generalizar a muchas dimensiones y también puede ser tratado en un abordaje piramidal multiescala, esto quiere decir que se resuelve el problema de flujo óptico para varias resoluciones de las imágenes y los flujos estimados para cada nivel se suman, este tipo de abordaje permite estimar desplazamientos grandes a diferencia de otros algoritmos en los que su abordaje depende de disparidades definidas matemáticamente en función de la derivada [46].

Hasta este punto se ha revisado la mínima teoría necesaria, buscando que el lector pueda entender de mejor manera los siguientes capítulos de la tesis, incluyendo la metodología propuesta por este trabajo.

# Capítulo 3

## Materiales y Métodos

En este capítulo se describen las distintas etapas de la metodología del algoritmo de **STE** desarrollado. Antes de entrar en detalle a cada componente, se introduce al lector a una vista generalizada del algoritmo de **STE** desarrollado mediante un diagrama de bloques en el que se integran todos los componentes. Dicho diagrama se puede visualizar en la Figura 3.1.



**Figura 3.1:** Diagrama de bloques del algoritmo de STE implementado. Donde se denotan las bases de datos como BD y los ecocardiogramas como ecos. Además, las bases de datos, y, las etapas del convertidor de flujo disperso a denso (SDC), de la arquitectura para la estimación de flujo (GMA), de la arquitectura para la segmentación de la ROI (ROI-Seg) y del análisis de deformación (AD) se explican con detalle en las secciones 3.1, 4.2, 3.3, 3.4 y 3.5, respectivamente.

El diagrama tiene 2 caminos: a) el camino rojo que denota la secuencia de componentes para la estimación de la deformación en los distintos 16 segmentos del miocardio para los que se ha estandarizado el análisis de deformación [7] y b) el camino azul que denota la secuencia de componentes necesarios para el entrenamiento de la red empleada para la estimación de flujo, la cual tiene un módulo llamado Agregación de Movimiento Global (GMA, por sus siglas en inglés) y de la red convolucional usada para la segmentación, dichas redes serán explicadas más adelante.

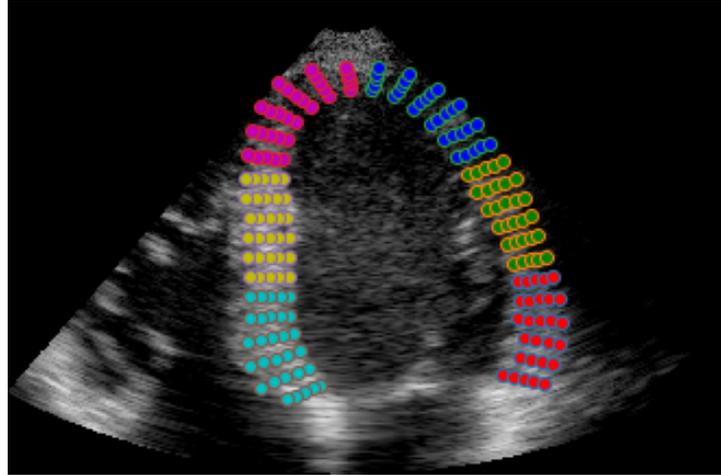
## 3.1. Bases de datos

En esta sección se establece una breve descripción de las distintas bases de datos con registros de ecocardiogramas utilizadas en el trabajo desarrollado.

### 3.1.1. Base de datos sintética

La base de datos sintética cuenta con ecocardiogramas que simulan patrones de movimiento en las paredes del ventrículo, dicha base de datos es de acceso libre y fue generada con el objetivo de evaluar la exactitud de algoritmos de STE [3]. Para la generación de los ecocardiogramas los autores primero generaron el movimiento cardiaco sintético, el cual fue obtenido a partir de un modelo electromecánico complejo. Finalmente, obtuvieron la textura realista del ecocardiograma a partir de registros reales de ecocardiogramas adquiridos con distintos equipos, cabe resaltar que todos los registros fueron adquiridos durante un ciclo cardíaco. Dado lo anterior los registros de la base de datos tienen distintas resoluciones dependiendo del equipo de adquisición y distinto número de fotogramas.

Dicha base de datos tiene 105 secuencias sintéticas de ecocardiograma en las vistas A2C, A3C y A4C, además cuenta con patrones de movimiento de las paredes de pacientes isquémicos y sanos. Para cada registro se tiene además del ecocardiograma un arreglo reticulado de puntos ordenados a lo largo de las paredes del VI que se han denotado como puntos clave; este arreglo cuenta con 36 filas en dirección longitudinal y 5 columnas en dirección radial. La distribución reticulada de los puntos en esas posiciones fue generada con base en EACVI/A-SE/Industry task force [7], donde cada 6 renglones se divide un segmento diferente, teniendo los siguientes segmentos ordenados a lo largo de las paredes del VI en el sentido de las manecillas de reloj: base izquierda, medio izquierdo, apical izquierdo, apical derecho, medio derecho y base derecha. En la Figura 3.2 se aprecia un ejemplo de un fotograma de la base de datos con sus puntos clave ordenados longitudinalmente en la ROI (paredes del VI), dichos puntos clave tienen un color dependiendo del segmento asociado.



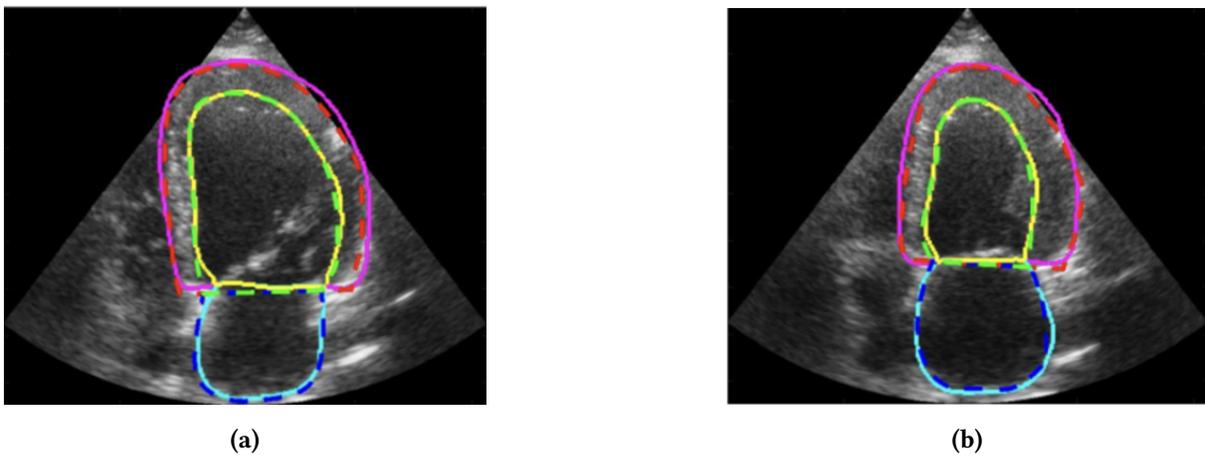
**Figura 3.2:** Ejemplo de un fotograma de un registro en la vista A4C de la base de datos sintética con su arreglo de puntos clave ordenados a lo largo de la ROI. Los puntos clave se visualizan con distintos colores dependiendo del segmento asociado.

Esta base de datos se usó para entrenar la red GMA, primero se obtuvo la diferencia entre las localizaciones de los puntos clave fotograma a fotograma obteniendo así una matriz de flujo bidimensional dispersa con la información del flujo en los puntos reticulados; dado que la red GMA se entrena con matrices de flujo densas (con información de flujo para cada pixel) se convirtió el flujo disperso a flujo denso mediante el convertidor de flujo que se explicará más adelante, entonces se usaron los puntos clave y la secuencia de ecocardiogramas para entrenar la red GMA, lo mencionado anteriormente se ilustra en la Figura 3.1. Así mismo, se usó la base de datos para evaluar las curvas de deformación por cada segmento que se obtienen a la salida del modelo respecto a las curvas de deformación obtenidas a partir de la secuencia de puntos clave.

### 3.1.2. Base de datos CAMUS

El conjunto de datos CAMUS consiste de distintos registros ecocardiográficos adquiridos en 500 pacientes en el Hospital de St Etienne mediante el equipo GE Vivid E95 ultrasound en las vistas A2C y A4C [12]. Cada registro cuenta con anotaciones de especialistas en el final de

la diástole y en el final de la sístole, dichas anotaciones son máscaras trazadas por el especialista para las distintas cavidades, como la pared externa e interna del VI y la AI. En la Figura 3.3 se muestra un ejemplo de un registro con las anotaciones del especialista. Este conjunto se usó para hacer el entrenamiento y la validación del algoritmo de segmentación semántica automática de las paredes cardíacas del VI en la vista A4C descrito más adelante, se emplearon 250 registros para el entrenamiento, debido a que solo se cuenta con 250 registros en la vista A4C.



**Figura 3.3:** Anotaciones de las distintas cavidades cardíacas en el final de la diástole (a) y el final de la sístole (b), ambas anotaciones son en la vista A4C [12].

En la Tabla 3.1 se agrupan las características más importantes de ambas bases de datos descritas anteriormente.

**Tabla 3.1:** Características de las bases de datos utilizadas.

	<b>Sintética</b>	<b>CAMUS</b>
<b>Uso</b>	Entrenamiento de red RAFT y evaluación de algoritmo de STE	Entrenamiento y evaluación de algoritmo supervisado de Segmentación
<b>Equipos de adquisición</b>	GE (Vivid E9), Hitachi (Prosound $\alpha$ 7), Esaote (MyLab Alpha), Philips (iE33), Samsung (EK07), Siemens (SC2000) y Toshiba (Artida )	GE Vivid E95
<b>Tamaño de conjunto de datos</b>	105 videos 2D	550 videos 2D
<b>Lugar de adquisición</b>	Hospital Gasthuisberg de la Universidad KU Leuven	Hospital de St Etienne
<b>Vistas</b>	A4C, A3C y A2C	A4C y A2C

### 3.1.3. Aumento de datos

Para incrementar el tamaño de la muestra y para aumentar las variaciones en los registros de electrocardiograma se propuso realizar aumento de datos modificando los fotogramas con artefactos modelados, relacionados con el proceso de adquisición de los registro de ultrasonido. Uno de estos artefactos se conoce como ruido multiplicativo, por lo que se generó de manera sintética este tipo de ruido y se agregó a la imagen de ecocardiograma, resultando en una imagen con ruido multiplicativo  $\mathbf{I}_r$ , donde la expresión matemática que describe lo anterior se muestra a continuación:

$$\mathbf{I}_r = \mathbf{I} + \mathbf{I} \odot \sigma_s \mathbf{G} , \quad (3.1)$$

donde  $\odot$  denota la multiplicación elemento a elemento entre matrices,  $\mathbf{I}$  denota a la matriz de intensidades de brillo de la imagen sin ruido,  $\mathbf{G}$  denota una matriz con las mismas dimensiones que  $\mathbf{I}$ , donde los valores provienen de una distribución gaussiana estándar y  $\sigma_s$  describe la desviación estándar del ruido *speckle*, siendo un parámetro libre a ajustar.

Otro tipo de artefacto es el sombreado acústico, el cual es causado por estructuras anatómicas que absorben o reflejan gran parte de la señal ultrasónica, este tipo de artefacto de sombreado es modelado como el resultado de multiplicar un kernel gaussiano espacial con alguna región de la matriz de intensidades de brillo de la imagen  $\mathbf{I}$ , la cual tiene dimensiones  $N \times M$ , dicho artefacto se modela con la siguiente expresión:

$$\mathbf{I}_{rX,rY} = \mathbf{I}_{rX,rY} \odot (\mathbf{U} - \lambda \mathbf{K}_G) , \quad (3.2)$$

donde  $\mathbf{K}_G$  es un kernel gaussiano 2D con media igual a cero, con un tamaño  $N_k \times N_k$  y una desviación estándar igual  $\sigma = \frac{N_k}{4}$ .  $\mathbf{U}$  es una matriz de unos con las mismas dimensiones que  $\mathbf{K}_G$ ,  $\lambda$  es un factor de atenuación y  $\mathbf{I}_{rX,rY}$  es la región donde se aplicará el sombreado, dicha región tiene las mismas dimensiones que el  $\mathbf{K}_G$  y esta centrada en los puntos  $rX$  y  $rY$ . En este caso los parámetros libre serían  $N_k$ ,  $\lambda$ ,  $rX$  y  $rY$ .

Empleando los artefactos explicados anteriormente, se incrementó la base de datos CAMUS de 500 a 36,000 fotogramas en la vista A4C con su respectiva máscara. Por otro lado, se aumentó la base de datos sintética de 2,037 a 6,113 pares de fotogramas en la vista A4C con sus matrices de flujo objetivo.

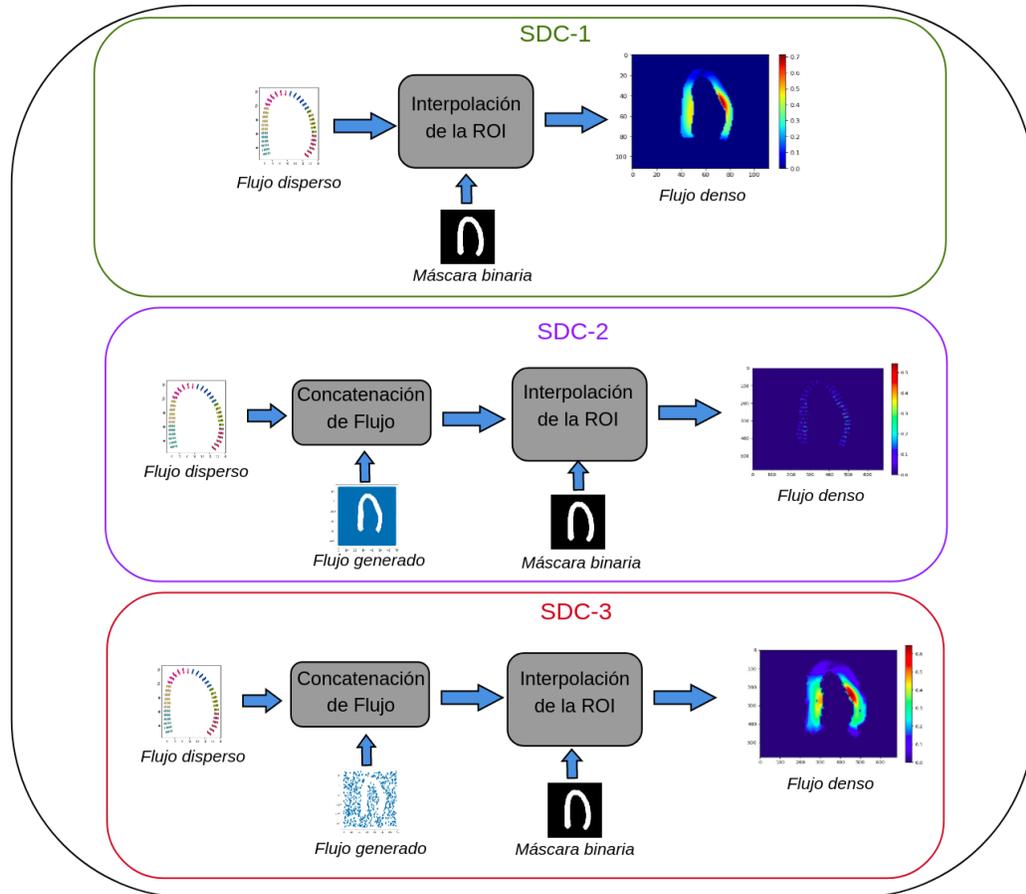
## 3.2. Convertidor de flujo disperso a denso (SDC)

Como se mencionó en la sección 3.1, a partir de los puntos clave de la base de datos sintética se puede calcular una matriz de flujo dispersa, sin embargo, la arquitectura usada para la estimación de flujo requiere matrices de flujo densas. Para ello, se desarrollaron 3 variantes de convertidores de flujo disperso a denso (SDC, por sus siglas en inglés): la primer variante se denotó como SDC-1, la cual realiza una interpolación espacial (2D) de la matriz dispersa de flujo, después se estableció con un valor de cero el flujo para todos los píxeles que no pertenecen a la región de interés (ROI, por sus siglas en inglés), donde en este caso la ROI contempla el miocardio del VI.

Para establecer con un valor de cero el flujo en los píxeles que no pertenecen a la ROI es necesario construir una máscara binaria que identifique la ROI. Para la construcción de la máscara primero se obtiene el contorno de la pared del VI, ordenando los puntos clave en el sentido de las manecillas de reloj, interpolando unidimensionalmente los puntos clave del endocardio y pericardio (primera y última columna de los puntos clave de la Figura 3.2) longitudinalmente a lo largo de las paredes del ventrículo y uniendo ambas secuencias de puntos para cerrar el contorno. Después se considera que cada punto es un vértice del polígono que representa la máscara, dado lo anterior se crea una máscara binaria que tenga valores distintos de cero en la superficie acotada por el polígono y se redimensiona al tamaño de las imágenes ecocardiográficas.

La segunda (SDC-2) y tercer variante (SDC-3) de los convertidores de flujo disperso a den-

so comparten una metodología similar. Ambas variantes primero generan puntos que tienen un valor de flujo igual a cero, éstos en posiciones aleatorias uniformemente distribuidas en las regiones que no pertenecen a la ROI. Estos puntos se generan mediante la repetición de  $N_P$  experimentos tipo Bernoulli, donde  $N_P$  es el número de píxeles que no pertenecen a la ROI, por consiguiente la probabilidad de tener  $k$  puntos generados está dado por la función de probabilidad binomial, debido a que se tiene considerado tener la misma probabilidad de éxito ( $p$ ) en todos los puntos, donde la función de probabilidad binomial esta dada por la siguiente expresión  $P(k) = \binom{N_P}{k} p^k (1-p)^{N_P-k}$ . Una vez que se generó la lista de puntos aleatorios con flujo cero, se concatenaron con la lista de puntos de flujo disperso y se realizó la interpolación 2D sobre dicha matriz, cuidando establecer con cero el valor del flujo para posiciones fuera de la ROI. Estas últimas variantes desarrolladas difieren solamente en la probabilidad de éxito establecida para la generación de puntos aleatorios, teniendo una  $p = 0.6$  para SDC-2 y una  $p = 0.002$  para el convertidor SDC-3. A continuación se ilustran los 3 algoritmos desarrollados para este trabajo de tesis en la Figura 3.4.



**Figura 3.4:** Diagramas de bloques de los 3 algoritmos desarrollados para la conversión de flujo disperso a flujo denso.

Para validar los convertidores de flujo disperso a denso; primero se evaluaron de manera cualitativa los resultados obtenidos por cada convertidor visualizando el mapa de desplazamiento denso generado, después, para cada convertidor que cualitativamente tuvo un buen rendimiento, se generaron mapas de desplazamiento denso a partir de 20 registros, tomados de manera aleatoria de la base de datos sintética. Posteriormente, se evaluaron de manera cuantitativa los mapas obtenidos, calculando las curvas de deformación para los distintos segmentos como se describe en la sección 3.5. Finalmente, se estimó la similitud que tienen las curvas estimadas con las curvas de referencia obtenidas a partir de los puntos clave, como métricas de similitud se usó la correlación de Pearson ( $\rho$ ) y la información mutua ( $MI$ ). Toda la evaluación cuantitativa se realizó para 3 distintos métodos de interpolación 2D (lineal, vecinos cercanos y cúbica).

### 3.3. Arquitectura para la estimación de flujo (GMA)

En esta sección se hablará de la arquitectura de aprendizaje profundo empleada para la estimación del campo de desplazamiento entre fotogramas. La estimación del campo de desplazamiento es la etapa más importante en la metodología del algoritmo de STE.

Antes de explicar la arquitectura GMA es necesario definir a una arquitectura predecesora, la cual es la base de GMA, ésta se llama Transformaciones de Campo Recurrentes sobre todos los Pares (RAFT, por sus siglas en inglés) [13], ésta se ilustra en la Figura 3.5. En la primera etapa de la arquitectura RAFT se codifican las características de ambos fotogramas y se codifica el contexto del segundo fotograma. El codificador de características  $g_\theta$  y el codificador de contexto  $h_\theta$  emplean la misma red neuronal convolucional, la cual está compuesta por 6 bloques residuales que tienen como objetivo extraer 256 mapas de características de las imágenes de entrada, reduciendo así mismo su resolución a  $\frac{1}{8}$  de su resolución original. Estos codificadores se pueden ver como operadores que actúan sobre imágenes y el mapeo que ofrecen estos operadores se describe en la siguiente expresión:

$$g_\theta, h_\theta : \mathbb{R}^{W \times H \times 3} \rightarrow \mathbb{R}^{\frac{W}{8} \times \frac{H}{8} \times 256} . \quad (3.3)$$

La segunda etapa de una RAFT es una capa de correlación, que obtiene un volumen de correlación entre los mapas de características obtenidos en la primera etapa, mediante el producto punto entre todos los pares de vectores de características. Resultando en un volumen de correlación con las siguientes dimensiones  $\frac{W}{8} \times \frac{H}{8} \times \frac{W}{8} \times \frac{H}{8}$ . En la ecuación 3.4 se muestra la expresión matemática para obtener el volumen de correlación 4D  $C_{ijkl}$ , donde  $i, j, k$  y  $l$  denotan los índices del volumen de correlación.

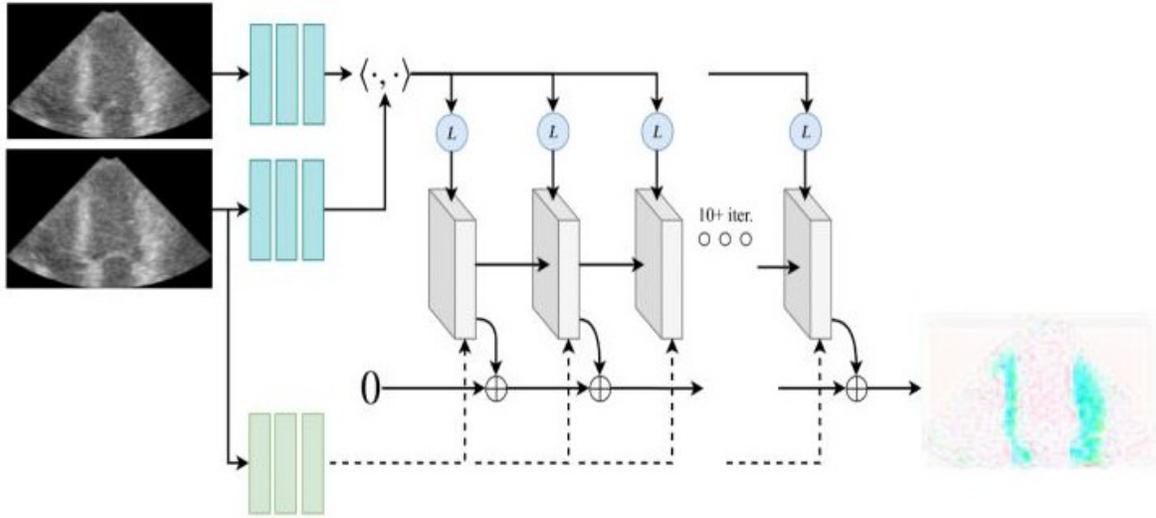
$$C_{ijkl} = \sum_h g_\theta(\mathbf{I}_1)_{ijh} g_\theta(\mathbf{I}_2)_{klh} , \quad (3.4)$$

donde  $\mathbf{I}_1$  y  $\mathbf{I}_2$  tienen dimensión  $W \times H$  y denotan el par de imágenes consecutivas en la entrada de la arquitectura. Después de obtener este volumen, se construye una estructura piramidal

con el fin de tener volúmenes a distintas escalas y así poder realizar estimaciones precisas, tanto para desplazamientos largos como cortos, para ello se aplica una capa de agrupamiento a lo largo de las últimas dos dimensiones con un tamaño de kernel de 1, 2, 4 y 8, permitiendo así reducir a la mitad la escala en cada nivel de la estructura piramidal. Finalmente, la última etapa de una arquitectura RAFT es una red recurrente que tiene como función de recurrencia la siguiente expresión:

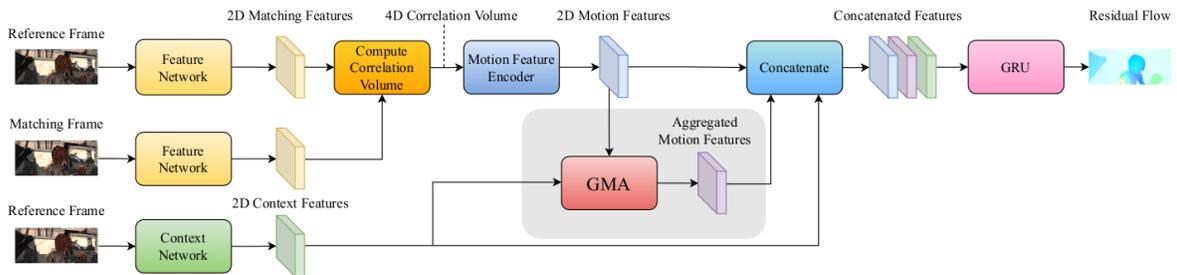
$$f_{k+1} = \Delta f + f_k , \quad (3.5)$$

donde  $\Delta f$  es el cambio de flujo, también conocido como flujo residual, que se suma al flujo en el instante anterior para obtener el flujo en el instante consecutivo. Para la estimación de  $\Delta f$  en cada iteración la unidad oculta recibe una variable de estado que resulta de concatenar el flujo, las correlaciones y las características de contexto. Como unidad oculta se utilizó una GRU, la cual tiene como principal objetivo el mantener dependencias de largo alcance sin que los gradientes se desvanezcan o estallen como se mencionó en la sección 2.4. En la Figura 3.5 se puede apreciar la arquitectura de la red RAFT y las predicciones de flujo obtenidas, a partir de fotogramas consecutivos de la base de datos sintética. Dicha red, se entrenó de igual manera que la arquitectura GMA y se detalla mas adelante en esta sección. En esta Figura las matrices de flujos se aprecian en el mapa de colores Tonalidad, Saturación y Valor (HSV, por sus siglas en inglés). Se puede apreciar que en el flujo estimado, no hay diferencias de tonos ni saturaciones para los distintos segmentos de las paredes cardíacas. Así como con este ejemplo, se realizó la predicción sobre muchos otros fotogramas consecutivos, obteniendo resultados similares, dado lo anterior se asumió de manera cualitativa que la arquitectura tiene una sensibilidad pobre para diferenciar el flujo entre los distintos segmentos, y se asumió que esta arquitectura no era la indicada para resolver nuestro problema de flujo óptico.



**Figura 3.5:** Arquitectura RAFT estimando el flujo entre dos fotogramas de la base de datos sintética [13].

La arquitectura GMA, a diferencia de una arquitectura RAFT, se especializa en la estimación de flujo en fotogramas con oclusiones; esta arquitectura agrega un módulo llamado agregación de movimiento global, este módulo emplea mecanismos de atención para crear relaciones en rangos amplios, esto con el fin de crear relaciones entre píxeles de manera no-local y poder transferir información a los píxeles ocluidos a partir de otros que no lo están. La arquitectura completa de GMA se muestra en la Figura 3.6.



**Figura 3.6:** Arquitectura GMA, la cual se basa en la arquitectura RAFT [14].

En este trabajo se usó la implementación de una arquitectura GMA a través de PyTorch, la cual es una biblioteca de aprendizaje automático de código abierto. Para validar y entrenar la red, se usaron 5,305 pares de fotogramas de la base de datos sintética aumentada en la

vista A4C con su respectivo campo de desplazamiento denso, obtenido a partir del convertidor SDC-3, el modelo obtenido se nombró Augmented-GMA. De la misma manera, se propone un segundo modelo entrenado con la misma base de datos pero sin aumento de datos, este segundo modelo se nombró GMA. El número de ejemplos utilizados para el conjunto de entrenamiento, validación y prueba para ambos modelos se describe en la Tabla 3.2. El entrenamiento de los modelos fue realizado en un servidor con una GPU Quadro RTX 8000 de Nvidia del Laboratorio de Cómputo de Alto Rendimiento de la ENES-Juriquilla. Para la etapa de entrenamiento se deben de considerar como parámetros la tasa de aprendizaje, número de iteraciones de la etapa recurrente, el tamaño de lote, la tasa de decaimiento y el tipo de optimizador. Para la etapa de evaluación de los modelos, se consideraron como conjuntos de prueba 808 ejemplos de la base de datos sintética con aumento y sin aumento, los cuales no se utilizaron ni para el entrenamiento ni para la validación. Después de estimar con ambos modelos el flujo en los conjuntos de prueba, se plantea como métrica o figura de mérito el EPE calculado en la ROI. Para tener un marco de referencia se implementa el algoritmo de Farnebäck, en el que se establece como parámetros una escala piramidal de 0.5, 3 niveles piramidales, un tamaño de ventana de 69 píxeles, 5 iteraciones para cada escala, 5 píxeles para la expansión del polinomio y un factor de suavizado de 1.1. Estos parámetros se definieron con base en la optimización por rejilla hecha por Østvik *et al.* [1], una vez establecidos los parámetros se obtiene el EPE. Finalmente, se considera utilizar estadística descriptiva no paramétrica para comparar la figura de mérito de las 3 implementaciones, mediante diagramas de cajas y bigotes.

**Tabla 3.2:** Conjuntos de la BD sintética sin aumento y con aumento, los cuales se usaron para entrenar el modelo GMA y Augmented-GMA, respectivamente.

<b>Tamaño muestra</b>	2,037
<b>Conjunto entrenamiento</b>	1,762
<b>Conjunto de prueba</b>	275

<b>Tamaño muestra</b>	6,113
<b>Conjunto entrenamiento</b>	5,305
<b>Conjunto de prueba</b>	808

### 3.4. Arquitectura para la segmentación de la ROI (ROI-Seg)

Para este trabajo se plantea la implementación de un algoritmo de segmentación semántica automática con el objetivo de extraer la máscara binaria del miocardio del VI en la vista A4C como ROI, para después definir espacialmente las regiones que acotan los distintos 16 segmentos del miocardio para los que se ha estandarizado el análisis de deformación [7].

Al consultar el estado del arte se encontró que en los últimos años los algoritmos basados en CNN han sido ampliamente utilizados para problemas de visión computacional, como el de segmentación semántica automática en imágenes médicas, donde la arquitectura más empleada y estable para esta tarea es la U-Net [47].

Ea por ello que para este trabajo se plantea una arquitectura que se denotará como ROI-Seg, la cual se basa en la arquitectura U-Net, a diferencia de la U-Net, esta arquitectura cuenta con algunas modificaciones, como la adición de lazos de alimentación residuales entre bloques consecutivos como lo propusieron en la arquitectura ResNet propuesta por He *et al.* [48], esto en vez de hacerlo entre bloques de la fase de decodificación y codificación como se emplea en U-Net. Los lazos residuales pueden reducir en gran medida el problema de degradación causado por la profundidad de la red, además, con los lazos residuales como se ha publicado en distintos trabajos se tiene una mayor convergencia al mínimo error tanto en el entrenamiento como en la validación. Es importante incrementar la profundidad de la red sin que se desvanezcan los pesos, ya que facilita la reducción del error en el estado estacionario de las épocas. Esta arquitectura además cuenta con capas para la normalización de los lotes de las imágenes y los mapas de características, donde para reducir el número de operaciones se utilizaron convoluciones separables.

La implementación de la arquitectura fue desarrollada en TensorFlow, la cual es una librería de aprendizaje profundo como Pytorch. La arquitectura se ilustra en la Figura 3.7.

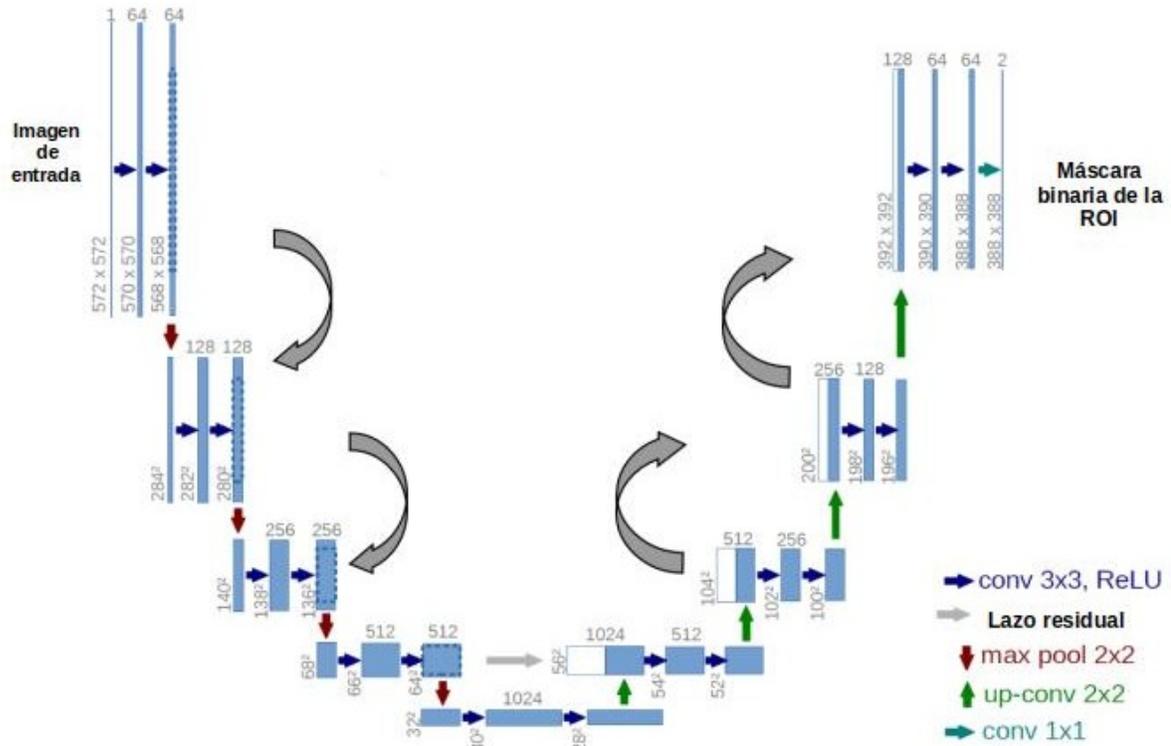


Figura 3.7: Arquitectura del modelo ROI-Seg basado en U-Net y ResNet.

Una vez establecido el modelo (ROI-Seg), se definen los parámetros para el entrenamiento de la red neuronal, primero se establece el optimizador ADAM, el cual ofrece ciertas ventajas como una tasa de aprendizaje adaptable en cada paso y un gradiente de salida estimado a partir del error cuadrático medio, que será propagado hacia atrás a través de cada una de las capas del modelo. Este algoritmo de segmentación se puede ver como un clasificador binario, por ello la última capa es una función de activación sigmoide. Para la validación, durante el entrenamiento se emplean como métricas la tasa de clasificación por píxel (exactitud) y la entropía cruzada binaria, esta última como métrica de pérdida. En la Tabla 3.3 se aprecia como se dividió la base de datos CAMUS para las tareas de entrenamiento, validación y prueba.

**Tabla 3.3:** Distribución de base de datos CAMUS aumentada para el entrenamiento, validación y prueba del algoritmo de segmentación.

<b>Tamaño muestra</b>	36,000
<b>Conjunto entrenamiento</b>	23,040
<b>Conjunto de validación</b>	5,760
<b>Conjunto de prueba</b>	7,200

Para la evaluación del modelo ROI-Seg se considera evaluar distintas métricas o figuras de mérito sobre el conjunto de prueba, dichas métricas se basan en el trabajo realizado por Popa *et al.* [49]. El conjunto de métricas se puede dividir en 2 subconjuntos: a) el primer subconjunto de métricas son para cuantificar la superposición de regiones entre la máscara binaria objetivo y la máscara binaria inferida por el modelo, b) el segundo subconjunto de métricas cuantifica la distancia entre los contornos de las máscaras binarias. Con dichas figuras de mérito se espera poder validar el modelo propuesto.

### 3.5. Análisis de deformación (AD) en la ROI

En esta sección se hablará acerca del último bloque del algoritmo de STE propuesto en la Figura 3.1, que corresponde a la etapa en la que se estiman las curvas de deformación de los distintos segmentos de las paredes del VI a lo largo de la secuencia de fotogramas de un registro de ecocardiograma 2D en la vista A4C. Así mismo, en esta etapa se estima un índice de función cardíaca a partir de estas curvas de deformación, el cual cuenta con un alto valor predictivo de enfermedades cardiovasculares en su etapa temprana como se comentó en la sección 2.2.3, este índice se conoce como GLS y puede ser calculado como el mínimo de la curva promedio de todos los segmentos.

Para esta etapa se utiliza como entrada la máscara binaria estimada de la ROI y a partir de ésta se genera un arreglo reticulado de puntos ordenados con la misma longitud de arco a lo largo de la ROI que denotamos previamente como puntos clave, para mayor detalle de la distribución de estos puntos clave en los distintos segmentos de la ROI revisar la sección 3.1.

Para obtener las curvas de deformación se extraen primero los puntos clave del primer fotograma del ecocardiograma, luego con los vectores de desplazamiento en las posiciones de los puntos clave de la matriz de flujo estimada se desplazan estos puntos a lo largo de las secuencias de fotogramas. Posteriormente, se calcula la longitud de arco para cada segmento utilizando una interpolación continua como se especifica en el trabajo desarrollado por M. Alessandrini *et al.* [3]. Finalmente, se estima la deformación longitudinal Langragiana con la siguiente expresión:

$$S_k = \frac{L_k - L_0}{L_0} \quad (3.6)$$

Donde  $L_0$  es la longitud de arco en el primer fotograma,  $L_k$  es la longitud del arco en el  $k$ -ésimo fotograma y  $S_k$  es la deformación longitudinal en  $k$ -ésimo fotograma. Lo anterior se repite para cada segmento y a lo largo de la secuencia de fotogramas para finalmente estimar las curvas de deformación longitudinal de cada segmento.

Después de obtener dichas curvas de deformación se implementa un filtro de promedio móvil para suavizar las curvas de deformación y mantener la coherencia temporal. En este trabajo se desarrollaron 2 variantes de **STE** basados en el diagrama de flujo de la Figura 3.1; el primer algoritmo utiliza el modelo GMA y se nombró como GMA-ST y el segundo algoritmo utiliza el modelo Augmented-GMA y se nombró como Aug-GMA-ST. Para la evaluación de los algoritmos implementados se utilizaron métricas empleadas en el estado del arte como la pendiente y la ordenada de una regresión lineal ajustada a las deformaciones estimadas respecto a las deformaciones de referencia, el coeficiente de correlación (de Pearson o Spearman, dependiendo de una prueba de gaussianalidad multivariada [50]) y el límite de concordancia con 95 % de confianza que existe en el ajuste de regresión lineal. Se realiza la evaluación de dichas métricas a partir del conjunto de prueba de la base de datos sintética no aumentada y se compararon con otros algoritmos de **STE** del estado del arte. Finalmente, para validar la estabilidad que tienen los algoritmos implementados, se utilizó una prueba de hipótesis para determinar si existe una diferencia significativa entre las estimaciones obtenidas del GLS en

registros con artefactos y sin artefactos. Además, se obtuvo un intervalo de confianza del 95 % del error obtenido en la estimación del índice GLS para los distintos algoritmos implementados.

En este capítulo se planteó la metodología y se detalló cada etapa de ésta, en el siguiente capítulo se presentarán los resultados obtenidos al evaluar cada etapa descrita en cada sección de este capítulo.

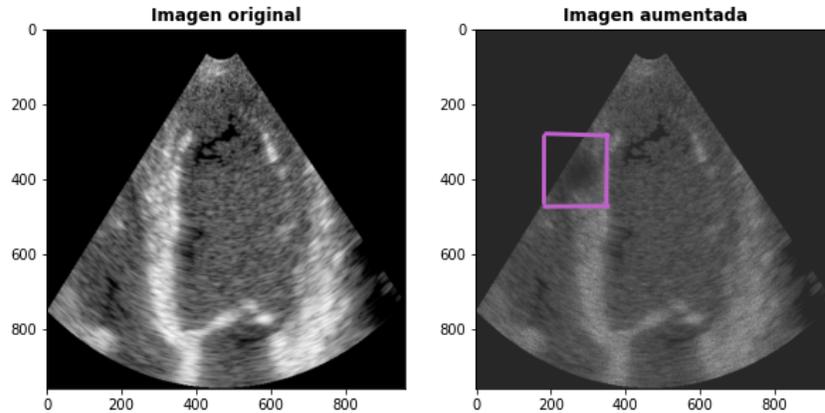
# Capítulo 4

## Resultados y Discusión

Este capítulo contiene los resultados obtenidos en cada sección de la metodología planteada en el Capítulo 3.

### 4.1. Aumento de datos

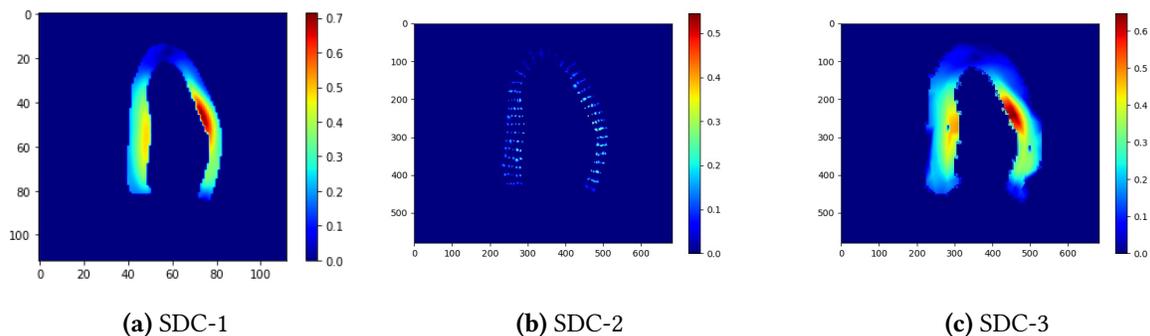
En el capítulo anterior se detallaron los artefactos sintéticos empleados para realizar el aumento de datos, el primer artefacto se presentó como ruido *speckle* y su expresión matemática se formalizó en la ecuación 3.1. El único parámetro a ajustar en dicha expresión es la desviación estándar del ruido *speckle*  $\sigma_s$ , la cual se estableció como una variable aleatoria uniformemente distribuida  $\sigma_s \sim U(0, 0.4)$ . El segundo artefacto se presentó como sombreado acústico y se representa con la expresión de la ecuación 3.2, donde como parámetros se establecieron las siguientes variables aleatorias:  $N_k \sim U(0.1, 0.9)$  ( $\min(N, M)$ ),  $\lambda \sim U(0.4, 0.9)$ ,  $r_X \sim U(\frac{N_k}{2}, M - \frac{N_k}{2})$  y  $r_Y \sim U(\frac{N_k}{2}, N - \frac{N_k}{2})$  [51]. Una vez establecidos los parámetros de ambos artefactos se realizó el aumento de datos sobre el conjunto de datos CAMUS y la base de datos sintética. A continuación en la Figura 4.1 se muestra un ejemplo del aumento del conjunto de datos sintético.



**Figura 4.1:** Aumento de un ecocardiograma de la base de datos sintética en la vista A4C, el aumento consiste de ruido *speckle* y sombreados gaussianos.

## 4.2. Validación del SDC

En esta sección se presentan los resultados obtenidos en la implementación de los 3 algoritmos de conversión de flujo disperso a flujo denso, para la generación de datos de entrenamiento para la arquitectura GMA. En la Figura 4.2 se observan los resultados obtenidos al convertir una matriz de flujo disperso a una matriz de flujo denso mediante los algoritmos SDC-1, SDC-2 y SDC-3, los cuales fueron previamente desarrollados siguiendo la metodología de la Figura 3.4.



**Figura 4.2:** Imágenes de flujo denso estimado a partir de los distintos convertidores de flujo desarrollados.

En la Figura anterior se aprecia que los algoritmos SDC-1 y SDC-3 tuvieron conversiones que de manera subjetiva se puede decir que se ven bien, a diferencia del algoritmo SDC-2.

Dado lo anterior, para la evaluación cuantitativa solo se considerarán los algoritmos SDC-1 y SDC-3. Como se mencionó en la sección 4.2, para dicha evaluación se emplean distintas métricas de similitud como la  $\rho$  y la  $MI$ . A continuación se muestra una tabla comparativa con las métricas de similitud para el convertidor SDC-1 y SDC-3, ésto para los 3 distintos métodos de interpolación 2D mencionados en la sección 4.2.

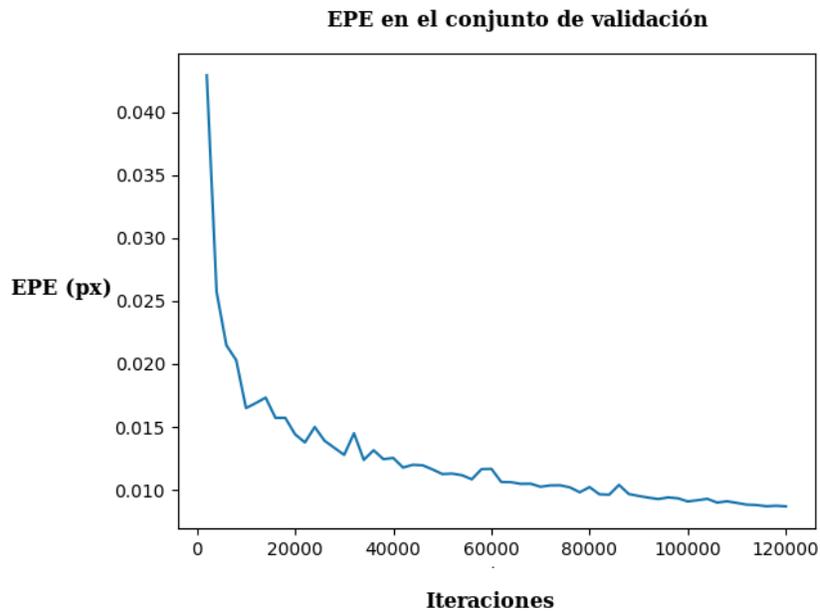
**Tabla 4.1:** Comparación de métricas de similitud entre SDC-1 y SDC-3 para 3 distintos métodos de interpolación.

N = 20	SDC-1		SDC-3	
Métodos	$\rho$	MI (nats)	$\rho$	MI (nats)
Vecinos Cercanos	$0.96 \pm 0.02$	$1.49 \pm 0.19$	$0.97 \pm 0.02$	$1.54 \pm 0.22$
Lineal	$0.52 \pm 0.18$	$1.15 \pm 0.17$	$0.95 \pm 0.03$	$1.48 \pm 0.21$
Cúbica	$0.51 \pm 0.18$	$1.16 \pm 0.16$	$0.93 \pm 0.06$	$1.47 \pm 0.22$

Como se muestra en la Tabla 4.1, el algoritmo SDC-1 mostró correlaciones bajas entre curvas de deformación para todos los métodos excepto para vecinos cercanos. Mientras que en el algoritmo SDC-3, las métricas de similitud fueron más altas tanto para la información mutua como para la correlación, de hecho para todos los registros y segmentos de las paredes del VI se encontró que las curvas de deformación están correlacionadas de manera significativa con un 95 % de confianza. Con base en lo anterior se puede asumir que el convertidor SDC-3 tiene un mejor comportamiento.

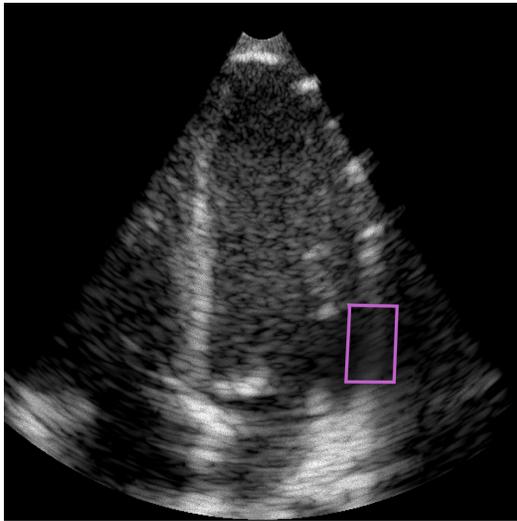
### 4.3. Validación de la arquitectura GMA

Como se mencionó en el capítulo pasado se propusieron dos modelos de GMA, de los cuales se establecieron los siguientes parámetros de entrenamiento: tasa de aprendizaje de 0.000125, 120,000 iteraciones, un tamaño de lote de 6 ejemplos, una tasa de decaimiento de 0.00001 y un optimizador ADAMW. Dado lo anterior se entrenaron ambos modelos, obteniendo una convergencia de los valores de pérdida (EPE) como la que se aprecia en la Figura 4.3, ésto evaluado en el conjunto de validación sobre cada una de las 120,000 iteraciones establecidas.

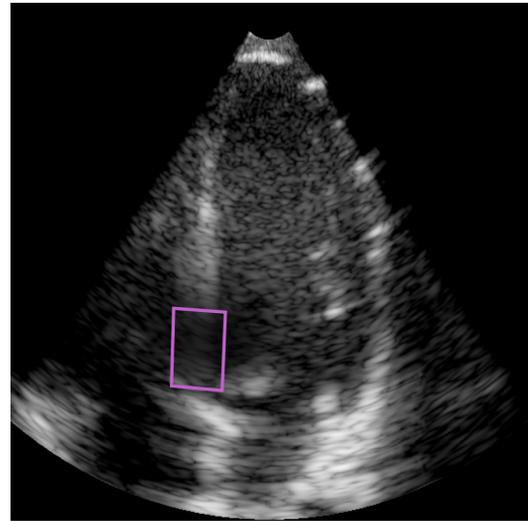


**Figura 4.3:** Convergencia de los valores de pérdida (EPE).

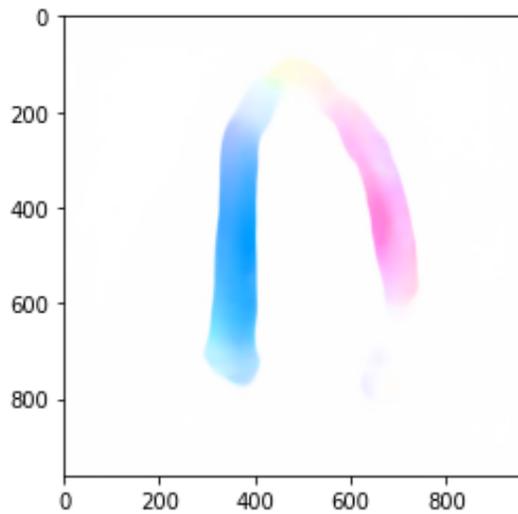
En la Figura 4.4 se aprecia un ejemplo de una predicción hecha por el modelo GMA sobre un par de fotogramas del conjunto de prueba aumentado, como se puede apreciar en dicha figura el modelo fue capaz de estimar el flujo en el segmento basal izquierdo a pesar de que en esa región en el fotograma 46 había un sombreado sintético. Sin embargo, el modelo no fue capaz de estimar el flujo en el segmento basal derecho debido a que el fotograma anterior venía con un sombreado sintético en esa región.



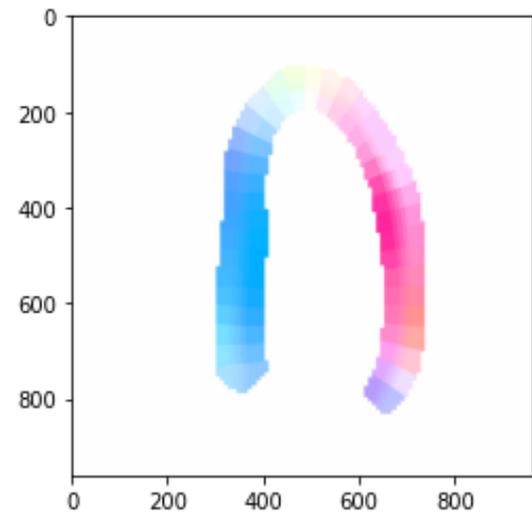
(a) Fotograma 45



(b) Fotograma 46



(c) Campo de desplazamiento estimado

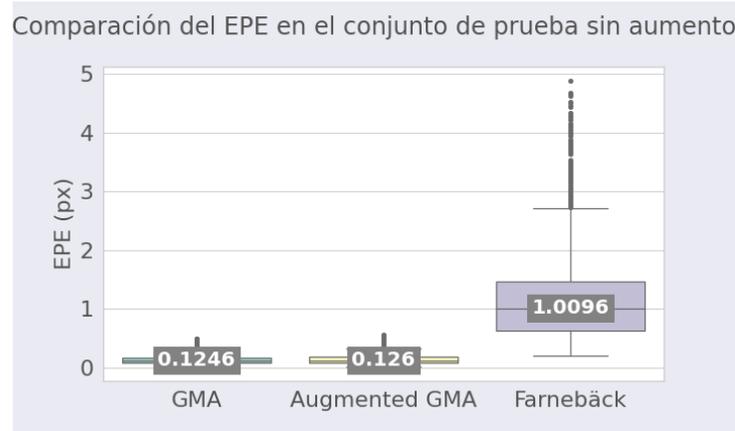


(d) Campo de desplazamiento de referencia

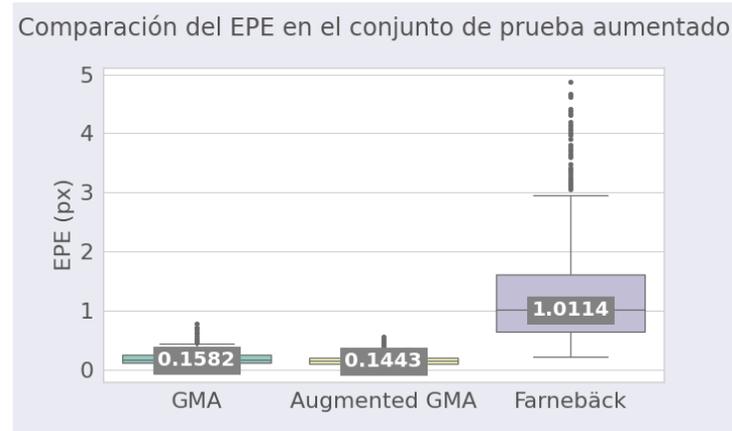
**Figura 4.4:** Campo de desplazamiento estimado con el modelo GMA a partir de 2 fotogramas consecutivos del conjunto de prueba aumentado y el campo de desplazamiento de referencia. Ambos campos de desplazamiento se visualizan en el mapa de colores HSV, representando con la tonalidad la fase del vector de desplazamiento y la saturación para la magnitud de dicho vector. En los fotogramas se indica con un recuadro la región que tiene oclusiones generadas por artefactos de sombreado acústico sintético.

Para validar los modelos entrenados se evaluó el EPE sobre el conjunto de prueba con y sin aumento de datos, comparándose con el algoritmo de Farneback. En la Figura 4.5 se aprecia dicha comparación mediante un diagrama de cajas y bigotes que ilustra la estadística

descriptiva no paramétrica de cada algoritmo a comparar.



(a) Conjunto de prueba sin aumento.



(b) Conjunto de prueba aumentado

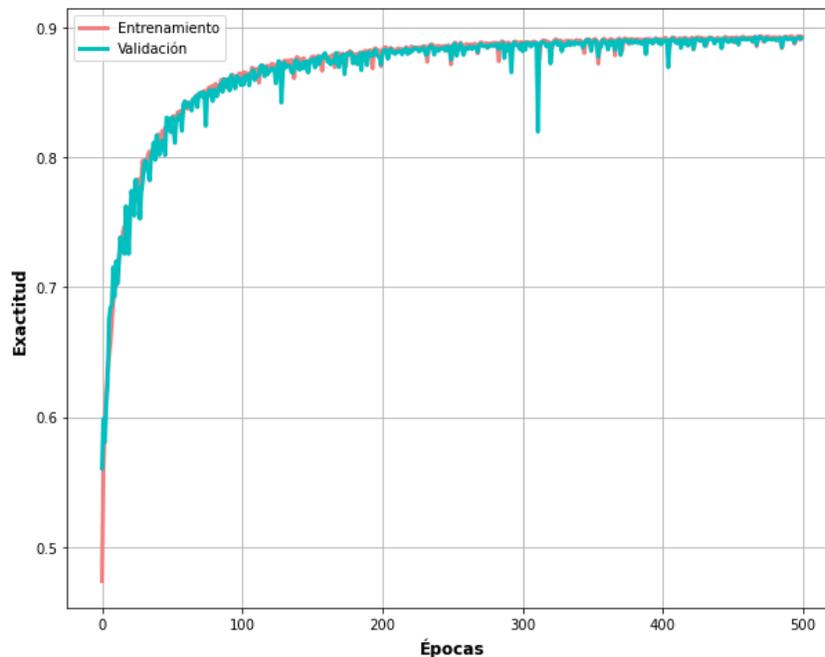
**Figura 4.5:** Comparación del EPE entre el modelo GMA, Augmented-GMA y el algoritmo de Farneback mediante un diagrama de cajas y bigotes, la evaluación se llevó a cabo sobre el conjunto de prueba aumentado y sin aumento.

De la Figura 4.5 se puede sugerir que los modelos basados en la arquitectura GMA tienen un mejor rendimiento en la estimación del campo de desplazamiento, debido a que la mediana del EPE de dichos modelos es 7.9 veces menor en comparación con el algoritmo de Farneback. Así mismo, el modelo Augmented-GMA es ligeramente mejor (una mediana del EPE 9 % menor) que el modelo GMA, éste evaluado en el conjunto de prueba aumentado. Esto último sugiere, que aunque no se entrene el modelo con una base de datos aumentada, el modelo tendrá un rendimiento muy similar al modelo entrenado con una base de datos aumentada, esto puede estar aunado a que la arquitectura GMA naturalmente se adapta a registros ruidosos, en

especial en registros con oclusiones que en ecocardiogramas se atribuye a sombreados acústicos. Los modelos obtenidos tardan en promedio 1.2 segundos en estimar el flujo en un par de fotogramas en una computadora de escritorio con una GPU GTX 1660 ti de Nvidia, lo cual es consistente con los algoritmos de flujo óptico, ya que son la familia de algoritmos que en el estado del arte eran más rápidos.

#### 4.4. Validación de la arquitectura ROI-Seg

En esta sección se presentarán los resultados obtenidos del algoritmo de segmentación, primeramente se muestra el resultado del entrenamiento, realizado sobre ROI-Seg en una computadora de escritorio con una GPU de Nvidia GTX 1660 ti. En la Figura 4.6 se muestra la convergencia de la métrica de exactitud a lo largo de las épocas de entrenamiento, tanto para el conjunto de entrenamiento como para el conjunto de validación.



**Figura 4.6:** Exactitud del modelo obtenida durante cada época del entrenamiento para el conjunto de entrenamiento y validación.

Una vez ajustado el modelo se obtuvieron las métricas de superposición de Jaccard, Dice (F-1) y la exactitud, así mismo se obtuvo la distancia de Hausdorff para medir la distancia entre los contornos como se mencionó en el capítulo anterior. En el caso de las métricas de superposición se espera un valor entre 0 y 1, siendo que el valor de 1 asegura una superposición perfecta entre ambas máscaras para todos los valores de los píxeles. La distancia de Hausdorff es la máxima distancia entre el contorno de la máscara binaria de referencia y la máscara binaria estimada, esta métrica debe de ser cero cuando la disparidad entre contornos es nula. El resultado de evaluar la arquitectura de segmentación se detalla en la Tabla 4.2.

**Tabla 4.2:** Métricas para evaluación del algoritmo de segmentación calculadas sobre el conjunto de prueba (7,200).

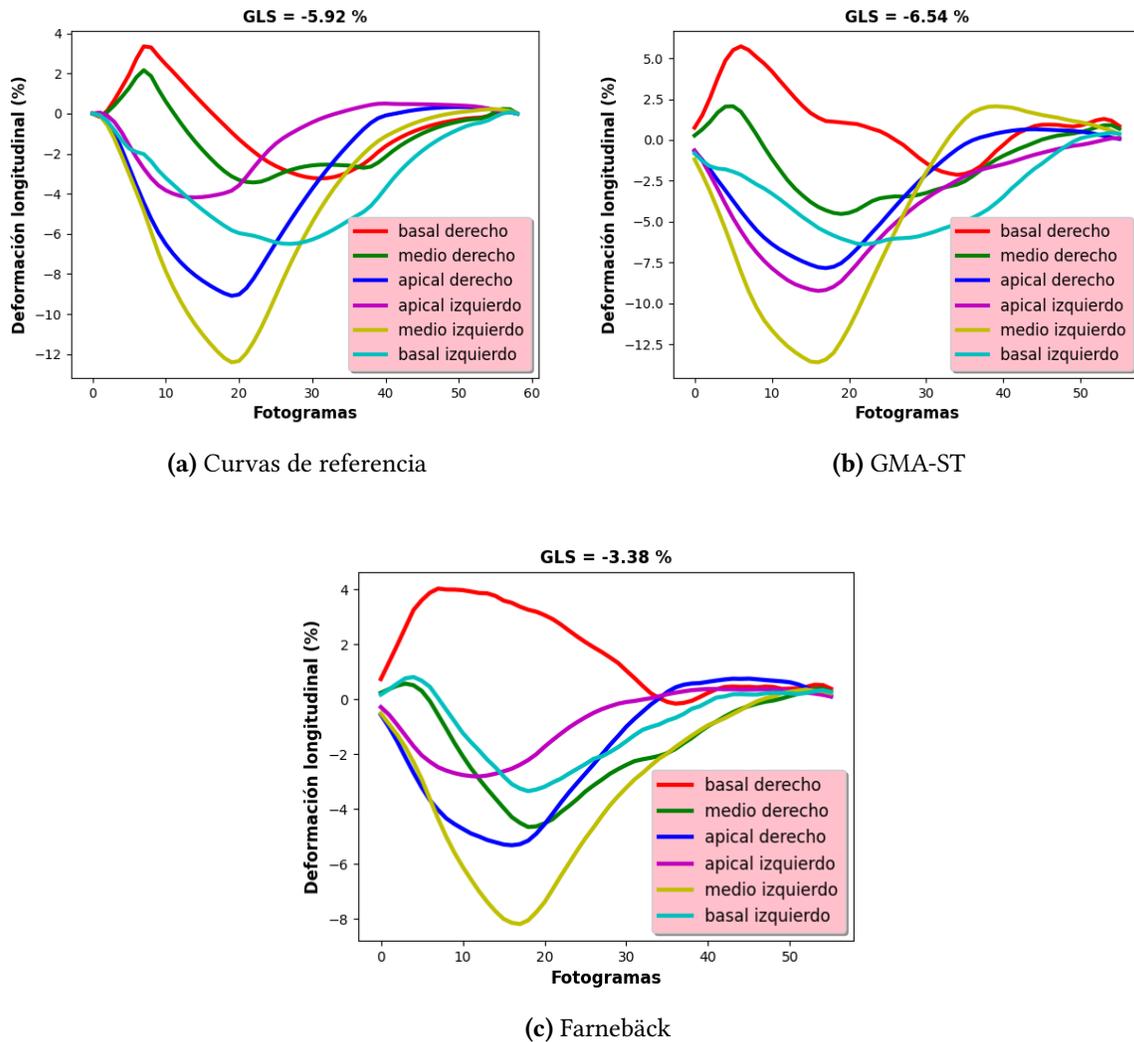
Métricas	Valores
Dice (F-1)	88.2 ± 3.8 %
Jaccard	79.1 ± 5.9 %
Exactitud	97.8 ± 0.7 %
Hausdorff distance	1.4 ± 0.2 mm

Como se puede apreciar en la Tabla 4.2 el algoritmo de segmentación destaca con sus métricas de superposición, adicionalmente, reporta una distancia promedio de Hausdorff de 1.4 mm.

## 4.5. Validación de la etapa de AD

En esta etapa se presentarán los resultados correspondientes al bloque del algoritmo de STE en donde se construyeron las curvas de deformación y se estimó la GLS.

Después de desplazar los puntos clave con la información de flujo y de estimar la deformación longitudinal para cada segmento en cada fotograma, se construyeron unas curvas de deformación como las que se aprecian en la Figura 4.7. Cada curva corresponde a la deformación longitudinal porcentual a lo largo de los fotogramas de cada segmento, dichos segmentos son diferenciados por colores como se aprecia en la Figura 4.7.



**Figura 4.7:** Se presentan las curvas de deformación longitudinal a lo largo de la secuencia de fotogramas de un registro sintético de un paciente normal en la vista A4C. El inciso a) corresponde a las curvas de referencia, el inciso b) presenta las curvas estimadas por el algoritmo de **STE** GMA-ST y el inciso c) muestra las curvas de deformación obtenidas mediante el algoritmo de Farnebäck.

Después se procedió a evaluar de manera cuantitativa como lo han hecho otros algoritmos de **STE** y se detalla en la Tabla 4.3, donde se ajusta una regresión lineal entre los valores de deformación estimados y los valores de deformación de referencia; posteriormente se toma como métricas la pendiente del ajuste ( $\alpha$ ), la ordenada al origen ( $\mu$ ), el límite de concordancia del ajuste con un 95 % de nivel de confianza (LOA) y el coeficiente de correlación ( $\rho$ ) de Pearson

o Spearman, sujeto a una prueba de hipótesis multivariada de gaussianalidad.

**Tabla 4.3:** Comparación entre los algoritmos de **STE** propuestos y los algoritmos revisados en el estado del arte, usando como figuras de mérito la pendiente de la regresión lineal ajustada ( $\alpha$ ), el coeficiente de correlación ( $\rho$ ), la ordenada de la regresión ( $\mu$ ) y el límite de concordancia de la regresión con un 95 % de nivel de confianza (LOA). Ésto fue evaluado sobre toda la base de datos sintética sin aumento (2,037)

Métodos	$\alpha$	$\rho$	$\mu$ (%)	LOA (%)
Alesandrini <i>et al.</i> [3]	0.55	0.75	0.37	6.98
Farnebäck	3.37	0.62	4.70	11.84
BM Optimizado [24]	<b>0.94</b>	<b>0.97</b>	0.12	3.43
EchoPWC-Net-us [1]	0.60	0.84	0.11	5.45
GMA-ST (Romero-Pacheco <i>et al.</i> [52])	1.20	0.85	<b>0.08</b>	<b>2.16</b>
Aug-GMA-ST (Romero-Pacheco <i>et al.</i> [52])	1.11	0.80	-0.15	2.61

Después de la revisión hecha en la sección 1.1, se concluyó que el mejor algoritmo de los trabajos presentados en el estado del arte era el algoritmo de BM Optimizado desarrollado por Azarmehr *et al.* [24], sin embargo, había otros algoritmos como el algoritmo EchoPWC-Net-us desarrollado por Østvik *et al.* [1], donde se obtuvo un mapa de desplazamiento denso de la ROI, a diferencia de los otros algoritmos donde solo se estimaba el desplazamiento en los puntos clave. Además, en dicho trabajo se realizó una validación más robusta agregando artefactos sintéticos a la base de datos sintética, comprobando la estabilización del algoritmo ante registros ruidosos. En este trabajo se desarrolló una metodología similar a la realizada en EchoPWC-Net-us y se comparó con los mejores algoritmos de **STE** revisados en la sección 1.1, dicha comparación se ilustra en la Tabla 4.3 donde se puede apreciar que el algoritmo de BM Optimizado tiene los mejores resultados en la métrica de  $\rho$  y en  $\alpha$ , sin embargo, la propuesta en este trabajo de tesis resultó tener mejores resultados en la métrica de  $\mu$  y en LOA. Después como se mencionó en el capítulo anterior se estiman los intervalos de confianza del error en la estimación del GLS con un 95 % de confianza, dicho intervalo se estima de manera paramétrica o no paramétrica (usando el método de Bootstrap [53]) dependiendo de una prueba de normalidad [50]. Finalmente, se realiza una prueba hipótesis para evaluar si existe una diferencia

significativa entre el GLS estimado en el conjunto aumentado y el GLS estimado en el conjunto sin aumento, ésto para evaluar la estabilidad de los algoritmos implementados, dicha prueba de hipótesis se estima de manera paramétrica o no paramétrica (usando la prueba de rango con signo de Wilcoxon [54]) dependiendo de una prueba de normalidad y de diferencia entre varianzas. Los intervalos de confianza se muestran en la tabla 4.4. Es importante realizar esta validación ya que como se abordó en la sección 2.2, dicho índice tiene una gran capacidad para detectar patologías cardíacas en su etapa subclínica, por consecuente es vital que los métodos propuestos sean capaces de estimar dicho índice con gran exactitud y que la exactitud se mantenga estable ante registros ecocardiográficos con artefactos.

**Tabla 4.4:** Intervalos de confianza del error obtenido en la estimación del GLS entre los algoritmos de STE implementados para el conjunto de prueba aumentado y sin aumento de datos. El símbolo \* denota si la diferencia entre los GLS estimados es significativa.

Métodos	Conjunto de prueba aumentado (808)	Conjunto de prueba sin aumento (275)
Farnebäck *	$-7.78 \pm 1.47 \%$	$5.39 \pm 15.15 \%$
GMA-ST (Romero-Pacheco <i>et al.</i> [52]) *	$1.92 \pm 4.24 \%$	$1.34 \pm 2.34 \%$
Aug-GMA-ST (Romero-Pacheco <i>et al.</i> [52])	$2.87 \pm 1.65 \%$	$2 \pm 2.31 \%$

De los resultados obtenidos en la tabla 4.4 se puede concluir que solo el algoritmo Aug-GMA-ST es estable ante artefactos sintéticos, dado que no existe diferencia significativa entre los valores de GLS estimados en el conjunto de prueba aumentado y sin aumento. Además, de los intervalos de confianza se puede sugerir que se tiene un menor error en la estimación del índice GLS en los algoritmos derivados de la metodología propuesta.

En este capítulo se evaluó cada una de las etapas de la metodología propuesta, siendo la última etapa donde se compara la metodología planteada con los algoritmos de STE presentados en el estado del arte. Una vez presentados y discutidos los resultados, se cerrará este trabajo de tesis con una conclusión sobre los alcances de este trabajo y sobre el trabajo futuro.

# Capítulo 5

## Conclusiones y Trabajo Futuro

En este trabajo se presentó una nueva metodología de **STE** basada en la arquitectura GMA para la estimación de la deformación longitudinal de las paredes del VI a partir de ecocardiogramas 2D, en la vista A4C. Con base en los resultados presentados se puede concluir que el algoritmo propuesto GMA-ST tuvo las mejores métricas de evaluación junto con el algoritmo de BM Optimizado [24]. Sin embargo, a diferencia del algoritmo de BM Optimizado nuestra propuesta permite estimar un campo de desplazamiento denso en toda la ROI para un par de fotogramas en 1.2 segundos, mientras el algoritmo de BM Optimizado solo provee información de desplazamiento en los puntos clave y su tiempo de ejecución es de 10 segundos. Por consiguiente nuestro modelo provee mayor información de flujo que puede ser usada para proponer nuevos índices que sean capaces de aprovechar el campo de desplazamiento en toda la ROI. Así mismo, se demostró que el algoritmo Aug-GMA-ST es el único que cuenta con estabilidad para la estimación del índice de GLS ante registros de ecocardiogramas con artefactos sintéticos. Para trabajo futuro se espera poder validar nuestra propuesta con una base de datos de pacientes con patologías cardíacas con anotaciones e información de un especialista. Además, se espera poder desarrollar un índice cardíaco que aproveche el campo de desplazamiento denso estimado por nuestro modelo en la ROI que tenga un mayor poder predictivo de enfermedades cardíacas que el índice de GLS.

# Bibliografía

- [1] A. Østvik, I. M. Salte, E. Smistad, T. M. Nguyen, D. Melichova, H. Brunvand, K. Haugaa, T. Edvardsen, B. Grenne, and L. Lovstakken, “Myocardial function imaging in echocardiography using deep learning,” *IEEE Transactions on Medical Imaging*, 2021.
- [2] M. Alessandrini, B. Heyde, S. Queirós, S. Cygan, M. Zontak, O. Somphone, O. Bernard, M. Sermesant, H. Delingette, D. Barbosa, *et al.*, “Detailed evaluation of five 3d speckle tracking algorithms using synthetic echocardiographic recordings,” *IEEE Transactions on Medical Imaging*, vol. 35, no. 8, pp. 1915–1926, 2016.
- [3] M. Alessandrini, B. Chakraborty, B. Heyde, O. Bernard, M. De Craene, M. Sermesant, and J. D’Hooge, “Realistic vendor-specific synthetic ultrasound data for quality assurance of 2-d speckle tracking echocardiography: Simulation pipeline and open access database,” *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, vol. 65, no. 3, pp. 411–422, 2017.
- [4] A. J. Pappano and W. G. Wier, *Cardiovascular Physiology-E-Book*. Elsevier Health Sciences, 2018.
- [5] R. Lang, S. A. Goldstein, I. Kronzon, B. K. Khandheria, and V. Mor-Avi, “Ase’s comprehensive echocardiography,” 2016.
- [6] N. B. Schiller, P. M. Shah, M. Crawford, A. DeMaria, R. Devereux, H. Feigenbaum, H. Gutgesell, N. Reichek, D. Sahn, I. Schnittger, *et al.*, “Recommendations for quantitation of the left ventricle by two-dimensional echocardiography,” *Journal of the American Society of Echocardiography*, vol. 2, no. 5, pp. 358–367, 1989.

- [7] J.-U. Voigt, G. Pedrizzetti, P. Lysyansky, T. H. Marwick, H. Houle, R. Baumann, S. Pedri, Y. Ito, Y. Abe, S. Metz, *et al.*, “Definitions for a common standard for 2d speckle tracking echocardiography: consensus document of the eacvi/ase/industry task force to standardize deformation imaging,” *European Heart Journal-Cardiovascular Imaging*, vol. 16, no. 1, pp. 1–11, 2015.
- [8] M. Leung, M. Xie, E. Durmush, D. Y. Leung, and V. W. Wong, “Weight loss with sleeve gastrectomy in obese type 2 diabetes mellitus: impact on cardiac function,” *Obesity Surgery*, vol. 26, no. 2, pp. 321–326, 2016.
- [9] P. A. Iaizzo, *Handbook of cardiac anatomy, physiology, and devices*. Springer Science & Business Media, 2009.
- [10] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [11] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, “Learning phrase representations using rnn encoder-decoder for statistical machine translation,” *arXiv preprint arXiv:1406.1078*, 2014.
- [12] S. Leclerc, E. Smistad, J. Pedrosa, A. Østvik, F. Cervenansky, F. Espinosa, T. Espeland, E. A. R. Berg, P.-M. Jodoin, T. Grenier, *et al.*, “Deep learning for segmentation using an open large-scale dataset in 2d echocardiography,” *IEEE Transactions on Medical Imaging*, vol. 38, no. 9, pp. 2198–2210, 2019.
- [13] Z. Teed and J. Deng, “Raft: Recurrent all-pairs field transforms for optical flow,” in *European Conference on Computer Vision*, pp. 402–419, Springer, 2020.
- [14] S. Jiang, D. Campbell, Y. Lu, H. Li, and R. Hartley, “Learning to estimate hidden motions with global motion aggregation,” 2021.
- [15] M. Tee, J. A. Noble, and D. A. Bluemke, “Imaging techniques for cardiac strain and deformation: comparison of echocardiography, cardiac magnetic resonance and cardiac computed tomography,” *Expert Review of Cardiovascular Therapy*, vol. 11, no. 2, pp. 221–231, 2013.

- [16] S. Yusuf, S. Reddy, S. Ôunpuu, and S. Anand, "Global burden of cardiovascular diseases: part i: general considerations, the epidemiologic transition, risk factors, and impact of urbanization," *Circulation*, vol. 104, no. 22, pp. 2746–2753, 2001.
- [17] M. Mathur, H. Al Maluli, and P. Patil, "Assessment of cardiac function by echocardiography," *Current Treatment Options in Cardiovascular Medicine*, vol. 17, no. 8, pp. 1–13, 2015.
- [18] H. Geyer, G. Caracciolo, H. Abe, S. Wilansky, S. Carerj, F. Gentile, H.-J. Nesser, B. Khandheria, J. Narula, and P. P. Sengupta, "Assessment of myocardial mechanics using speckle tracking echocardiography: fundamentals and clinical applications," *Journal of the American Society of Echocardiography*, vol. 23, no. 4, pp. 351–369, 2010.
- [19] G. N. Shivu, K. Abozguia, T. T. Phan, I. Ahmed, R. Weaver, P. Narendran, M. Stevens, and M. Frenneaux, "Increased left ventricular torsion in uncomplicated type 1 diabetic patients: the role of coronary microvascular function," *Diabetes Care*, vol. 32, no. 9, pp. 1710–1712, 2009.
- [20] M. C. P. Nunes, L. P. Badano, J. A. Marin-Neto, T. Edvardsen, C. Fernández-Golfín, C. Bucciarelli-Ducci, B. A. Popescu, R. Underwood, G. Habib, J. L. Zamorano, *et al.*, "Multimodality imaging evaluation of chagas disease: an expert consensus of brazilian cardiovascular imaging department (dic) and the european association of cardiovascular imaging (eacvi)," *European Heart Journal-Cardiovascular Imaging*, vol. 19, no. 4, pp. 459–460n, 2018.
- [21] M. M. Barbosa, M. O. C. Rocha, D. F. Vidigal, R. de Carvalho Bicalho Carneiro, R. D. Araújo, M. C. Palma, M. V. L. de Barros, and M. C. P. Nunes, "Early detection of left ventricular contractility abnormalities by two-dimensional speckle tracking strain in chagas' disease," *Echocardiography*, vol. 31, no. 5, pp. 623–630, 2014.
- [22] S. Queirós, J. L. Vilaça, P. Morais, J. C. Fonseca, J. D'hooge, and D. Barbosa, "Fast left ventricle tracking in cmr images using localized anatomical affine optical flow," in *Medical Imaging 2015: Image Processing*, vol. 9413, p. 941306, International Society for Optics and Photonics, 2015.

- [23] B. Heyde, M. Alessandrini, J. Hermans, D. Barbosa, P. Claus, and J. D’hooge, “Anatomical image registration using volume conservation to assess cardiac deformation from 3d ultrasound recordings,” *IEEE Transactions on Medical Imaging*, vol. 35, no. 2, pp. 501–511, 2015.
- [24] N. Azarmehr, X. Ye, J. D. Howes, B. Docking, J. P. Howard, D. P. Francis, and M. Zolgharni, “An optimisation-based iterative approach for speckle tracking echocardiography,” *Medical & Biological Engineering & Computing*, vol. 58, no. 6, pp. 1309–1323, 2020.
- [25] O. Somphone, M. De Craene, R. Ardon, B. Mory, P. Allain, H. Gao, J. D’hooge, S. Marchesseau, M. Sermesant, H. Delingette, *et al.*, “Fast myocardial motion and strain estimation in 3d cardiac ultrasound with sparse demons,” in *2013 IEEE 10th International Symposium on Biomedical Imaging*, pp. 1182–1185, IEEE, 2013.
- [26] T. Liang, L. Yung, and W. Yu, “On feature motion decorrelation in ultrasound speckle tracking,” *IEEE Transactions on Medical Imaging*, vol. 32, no. 2, pp. 435–448, 2012.
- [27] M. Alessandrini, M. De Craene, O. Bernard, S. Giffard-Roisin, P. Allain, I. Waechter-Stehle, J. Weese, E. Saloux, H. Delingette, M. Sermesant, *et al.*, “A pipeline for the generation of realistic 3d synthetic echocardiographic sequences: Methodology and open-access database,” *IEEE Transactions on Medical Imaging*, vol. 34, no. 7, pp. 1436–1451, 2015.
- [28] P. y. I. E. y. H. P. y. H. C. y. G. V. y. V. D. S. P. y. C. D. y. B. T. Dosovitskiy, Alexey y Fischer, “Flownet: Learning optical flow with convolutional networks,” in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2758–2766, 2015.
- [29] E. Ilg, N. Mayer, T. Saikia, M. Keuper, A. Dosovitskiy, and T. Brox, “Flownet 2.0: Evolution of optical flow estimation with deep networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2462–2470, 2017.
- [30] X. y. L. M.-Y. y. K. J. Sun, Deqing y Yang, “Pwc-net: Cnns for optical flow using pyramid, warping, and cost volume,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 8934–8943, 2018.

- [31] G. Farneback, "Two-frame motion estimation based on polynomial expansion," in *Scandinavian Conference on Image Analysis*, pp. 363–370, Springer, 2003.
- [32] S. J. Trivedi, M. Altman, T. Stanton, and L. Thomas, "Echocardiographic strain in clinical practice," *Heart, Lung and Circulation*, vol. 28, no. 9, pp. 1320–1330, 2019.
- [33] N. Wenger, W. Boden, B. Carabello, R. Carney, M. Cerqueira, and M. Criquel, "Cardiovascular disability: Updating the social security listings," *National Academy of Sciences*, 2010.
- [34] J. A. M. Carabetti, "Cardiomiopatía diabética," *Revista Uruguaya de Cardiología*, vol. 32, no. 3, pp. 264–276, 2017.
- [35] P. A. Valencia J., Vallverdú M., "Heart rate variability analysis in ischemic cardiomyopathy and aortic stenosis patients." [http://www.eulate.net/actividades/docos/PMcarACT\\_fa8506.pdf](http://www.eulate.net/actividades/docos/PMcarACT_fa8506.pdf), 2013.
- [36] C. M. Oakley, "Myocarditis, pericarditis and other pericardial diseases," *Heart*, vol. 84, no. 4, pp. 449–454, 2000.
- [37] S. S. PM, I. de Haro Arteaga, *et al.*, "Chagas disease in México," *Parasitology Today (Personal ed.)*, vol. 4, no. 12, pp. 348–352, 1988.
- [38] W. H. Organization *et al.*, "Chagas disease in latin america: an epidemiological update based on 2010 estimates," *Weekly Epidemiological Record= Relevé épidémiologique hebdomadaire*, vol. 90, no. 06, pp. 33–44, 2015.
- [39] A. García-Álvarez, M. Sitges, A. Regueiro, S. Poyatos, M. J. Pinazo, E. Posada, B. Bijnens, M. Heras, J. Gascon, and G. Sanz, "Myocardial deformation analysis in chagas heart disease with the use of speckle tracking echocardiography," *Journal of Cardiac Failure*, vol. 17, no. 12, pp. 1028–1034, 2011.
- [40] T. F. Cianciulli, G. A. Albarracín, M. Napoli Llobera, N. G. Prado, M. C. Saccheri, Y. M. Hernández Vásquez, R. J. Méndez, M. A. Beck, K. G. Baez, and L. R. Balletti, "Speckle tracking echocardiography in the indeterminate form of chagas disease," *Echocardiography*, 2020.

- [41] C. Suaide and E. Carlos, “Ecocardiografía principios y aplicaciones clínicas,” *Caracas: AMOLCA*, 2010.
- [42] D. Pellerin, R. Sharma, P. Elliott, and C. Veyrat, “Tissue doppler, strain, and strain rate echocardiography for the assessment of left and right systolic ventricular function,” *Heart*, vol. 89, no. suppl 3, pp. iii9–iii17, 2003.
- [43] Z. U. Rahman, P. Sethi, G. Murtaza, H. U. H. Virk, A. Rai, M. Mahmud, J. Schoondyke, and K. Albalbissi, “Feature tracking cardiac magnetic resonance imaging: A review of a novel non-invasive cardiac imaging technique,” *World Journal of Cardiology*, vol. 9, no. 4, p. 312, 2017.
- [44] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O’Reilly Media, 2019.
- [45] J. Gibson and O. Marques, *Optical flow and trajectory estimation methods*. Springer, 2016.
- [46] B. D. Lucas, T. Kanade, *et al.*, “An iterative image registration technique with an application to stereo vision,” *Proceedings of Imaging Understanding Workshop*, 1981.
- [47] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 234–241, Springer, 2015.
- [48] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770–778, 2016.
- [49] T. Popa, L. Ibanez, E. Levy, A. White, J. Bruno, and K. Cleary, “Tumor volume measurement and volume measurement comparison plug-ins for volview using itk,” in *Medical Imaging 2006: Visualization, Image-Guided Procedures, and Display*, vol. 6141, p. 61411B, International Society for Optics and Photonics, 2006.
- [50] N. Henze and B. Zirkler, “A class of invariant consistent tests for multivariate normality,” *Communications in Statistics-Theory and Methods*, vol. 19, no. 10, pp. 3595–3617, 1990.

- [51] H. T. Le, N. Hangiandreou, R. Timmerman, M. J. Rice, W. B. Smith, L. Deitte, and G. M. Janelle, "Imaging artifacts in echocardiography," *Anesthesia & Analgesia*, vol. 122, no. 3, pp. 633–646, 2016.
- [52] J. P.-G. y. N. H.-M. A. Romero-Pacheco, "Estimating echocardiographic myocardial strain of left ventricle with deep learning," in *2022 44th Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, 2022.
- [53] T. J. DiCiccio and B. Efron, "Bootstrap confidence intervals," *Statistical science*, vol. 11, no. 3, pp. 189–228, 1996.
- [54] F. Wilcoxon, "Individual comparisons by ranking methods," in *Breakthroughs in statistics*, pp. 196–202, Springer, 1992.