

Reducción de ruido periódico en imágenes obtenidas por
perfilometría usando técnicas de aprendizaje profundo para
reconstrucción de objetos 3D

2023

Osmar Antonio
Espinosa Bernal



Universidad Autónoma de Querétaro
Facultad de Ingeniería

Reducción de ruido periódico en imágenes obtenidas por
perfilometría usando técnicas de aprendizaje profundo
para reconstrucción de objetos 3D

Tesis

Que como parte de los requisitos
para obtener el grado de

**Maestro en Ciencias en
Inteligencia Artificial**

Presenta:

Osmar Antonio Espinosa Bernal

Dirigido por:

Dr. Jesús Carlos Pedraza Ortega

Querétaro, Qro., a 26 de mayo de 2023



Dirección General de Bibliotecas y Servicios Digitales
de Información



Reducción de ruido periódico en imágenes obtenidas
por perfilometría usando técnicas de aprendizaje
profundo para reconstrucción de objetos 3D

por

Osmar Antonio Espinosa Bernal

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0
Internacional](#).

Clave RI: IGMAC-302396



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Ciencias en Inteligencia Artificial

Reducción de ruido periódico en imágenes obtenidas por perfilometría usando técnicas de aprendizaje profundo para reconstrucción de objetos 3D.

TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias en Inteligencia Artificial

Presenta:

Ing. Osmar Antonio Espinosa Bernal

Dirigido por:

Dr. Jesús Carlos Pedraza Ortega

SINODALES

Dr. Jesús Carlos Pedraza Ortega
Presidente

Dr. Marco Antonio Aceves Fernández
Secretario

Dr. Saúl Tovar Arriaga
Vocal

Dr. Juan Manuel Ramos Arreguín
Suplente

Dr. Efren Gorrostieta Hurtado
Suplente

Centro Universitario
Querétaro, QRO
México.
26 de mayo de 2023

© 2023 - Ing. Osmar Antonio Espinosa Bernal

All rights reserved.

This thesis is dedicated to my family

Agradecimientos

To Conacyt for the scholarship given for two years, which allow me to complete the master of science in artificial intelligence at the Autonomous University of Queretaro.

To mi family, for all the support given to me during this two years journey and to my proffesors, for passing on their knowledge onto us and sharing their time and experience with me. Especially, thank you to my thesis director: Dr. Jesús Carlos Pedraza Ortega. I couldn't haven chosen a better person to lead me during this time.

Abstract

One of the most important tasks in the area of computer vision is the acquisition of 3D objects from 2D images. Among the methods used for this purpose is the so-called fringe profilometry which allows, by projecting a pattern of fringes on an object, to obtain the shape of the object, which, applied with pixel matching techniques, reconstructs the 3D object. Given the speed and simplicity of a system for obtaining images with the fringe perphilometry method applying a 3-step displacement pattern, which captures 3 images for 3D reconstruction, this technique has led to research to improve such system or an additional image preprocessing to obtain 3D objects quickly and the closest thing to the original object. Using image preprocessing techniques it is possible to improve the reconstruction of 3D objects by generating smoother objects with surfaces close to the real object. The use of convolutional neural networks with a set of preprocessed images to improve the generation of 3D objects allows us to obtain 3D objects faster and more automatically, increasing the precision of 3D object. With the pre-processing applied to images that contain the 2D information of real 3D objects, it is possible to improve the 3D reconstruction, using the system to obtain objects of any shape and size.

(Keywords: Convolutional Neural Networks, Fringe projection profilometry, phase unwrapping, 3-Step, 3D reconstruction, filter, Moire noise.)

Resumen

Una de las tareas más importantes en el área de la visión artificial es la adquisición de objetos 3D a partir de imágenes 2D. Entre los métodos utilizados para este fin se encuentra la llamada perfilometría de franjas que permite, mediante la proyección de un patrón de franjas sobre un objeto, obtener la forma del objeto, que, aplicada con técnicas de correspondencia de píxeles, reconstruye el objeto 3D. Dada la rapidez y sencillez de un sistema de obtención de imágenes con el método de perfilometría de franjas aplicando un patrón de desplazamiento de 3 pasos, que captura 3 imágenes para su reconstrucción 3D, esta técnica ha dado lugar a investigaciones para mejorar dicho sistema o un pre-procesado adicional de imágenes para obtener objetos 3D de forma rápida y lo más parecida al objeto original. Usando técnicas de pre-procesamiento de imágenes es posible mejorar la reconstrucción de objetos 3D generando objetos más suaves con superficies cercanas al objeto real. El uso de redes neuronales convolucionales con un conjunto de imágenes pre-procesadas para mejorar la generación de objetos 3D nos permite obtener objetos 3D de forma más rápida y automática, aumentando la precisión de los sistemas generadores de objetos 3D. Con el pre-procesado aplicado a imágenes que contienen información 2D de objetos 3D reales, es posible mejorar la reconstrucción 3D utilizando el sistema para obtener objetos de cualquier forma y tamaño.

Abreviaturas y siglas

PSP - [Phase Shifting Perfilometry - Perfilometría de cambio de fase]

CNN - [Convolutional Neural Network - Redes neuronales convolucionales]

GPU - Graphics Processing Unit - Unidad de procesamiento gráfico

IA - Inteligencia Artificial

ReLU - Rectified Linear Units - Unidad Lineal Rectificada

RGB - Red Green Blue - Rojo Verde Azul

ATBFDF - Adaptive Threshold Base Frequency Domain Filter- Filtro adaptable basado en el dominio de la frecuencia

FCN- Fully Convolutional Network - Red neuronal completamente convolucional

Multiresultion-CNN - Multiresolution Convolutional Neural Network - Red Neuronal Convolutio-
nial Multiresolución

Índice general

Agradecimientos	I
Abstract	III
Resumen	V
Abreviaturas y siglas	VII
Contenido	IX
Lista de Figuras	XI
Lista de Tablas	XIII
1. Introducción	1
1.0.1. Visión por computadora	1
1.0.2. Redes neuronales convolucionales	2
1.0.3. Definición del problema	2
1.0.4. Justificación	2
1.0.5. Hipótesis	3
1.0.6. Objetivos	3
2. Antecedentes	5
2.1. Trabajos relacionados	5
2.1.1. Antecedentes de filtros para reducción de ruido en imágenes	6
2.2. Estado del arte	8
2.3. Principio de perfilometría de proyección de franjas y desenvolvimiento de fase.	10
2.4. Patrón de Moire	13
3. Metodología	15
3.1. Perfilometría por cambio de fase	15
3.2. Adquisición de imágenes	15
3.2.1. Extracción de fase y desenvolvimiento de fase	17
3.3. Filtrado de imágenes	18
3.3.1. Filtro de umbral adaptable en dominio de la frecuencia y suavizado en dominio espacial	20

3.4. Deep CNN	27
4. Resultados y Discusión	31
4.1. Base de datos de imágenes	31
4.2. Reconstrucciones 3D con algoritmo desarrollado	32
4.3. Filtro adaptativo y filtro de suavizado visto de cerca.	33
4.4. Entrenamiento de Red Neuronal Convolutiva Profunda (Deep CNN)	35
4.5. Comparación con otras arquitecturas	37
4.6. Resultados de entrenamiento usando GPU GeForce GTX 1070.	44
4.7. Resultados de entrenamiento usando mejores parámetros por cada modelo de red.	50
4.8. Resultados con objetos reales	55
4.9. Importancia/Impacto	56
4.9.1. Impacto Social	56
4.9.2. Impacto Ambiental	56
4.9.3. Impacto Económico	56
4.10. Publicaciones	56
4.11. Trabajo a futuro	57
5. Conclusiones	59
Referencias	64
.1. Registro de protocolo de investigación	65

Índice de figuras

2.1. a) Imagen Original, b) Imagen original con ruido periódico y c) imagen original con ruido cuasi/periódico.	6
2.2. Taxonomía de las técnicas de adquisición 3D [1].	10
2.3. Clasificación de las técnicas de adquisición óptica [1].	10
2.4. Sistema básico de perfilometría de proyección de franjas.	11
2.5. Diferentes patrones de barras usados en perfilometría de proyección franjas.	11
3.1. Trayectoria óptica de la perfilometría de medición de fase en el entorno emulado [2].	16
3.2. El árbol principal de nodos de composición de este sistema <i>Blender</i> [2].	17
3.3. Modelos del sitio <i>TurboSquid</i> [2].	17
3.4. Conjunto de imágenes obtenidos por escena: a), b), c) proyección de franjas con objeto y deslizamiento de fase de $2\pi/3$, d), e), f) proyección de franjas de referencia y deslizamiento de fase de $2\pi/3$, g) Groundtruth, h) Mascara con región de interés.	18
3.5. Mapas de fase objeto y de referencia.	19
3.6. Representación 3D de mapas de fase desenvueltos de objeto y de referencia.	19
3.7. Mapa de fase absoluta obtenida mediante la resta de mapa de fase de objeto y de plano de referencia. Se aprecia el ruido cuasi periódico que afecta la reconstrucción 3D del objeto.	19
3.8. Filtro de umbral adaptativo.	21
3.9. Pasos para aplicar filtro adaptable y filtro de suavizado.	22
3.10. Imagen en dominio de frecuencia con ruido de cuasi/periódico visibles.	23
3.11. Kernel Laplaciano de 5×5 usado para resaltar regiones con ruido cuasi/periódico.	23
3.12. Imagen en dominio de frecuencia con ruido cuasi/periódico resaltado mediante aplicación de convolucion con kernel Laplaciano de 5×5	24
3.13. Ajuste de contraste para resaltar regiones con ruido cuasi/periódico.	24
3.14. Imagen que muestra las regiones identificadas con ruido cuasi/periódico en el dominio de la frecuencia.	25
3.15. 1×7 vertical kernel [3].	26
3.16. 1×7 horizontal kernel [3].	26
3.17. a) Imagen contaminada antes de filtrado. b) Imagen contaminada después de filtrado.	26
3.18. Arquitectura propuesta de red neuronal convolucional profunda.	28
4.1. Conjunto de imágenes generados para creación de base de datos.	32
4.2. Reconstrucción de objeto 3D por etapas en visualización 2D.	33

4.3. Reconstrucción de objeto 3D.	33
4.4. Una vista cercana al ruido cuasi/periódico tratado con el filtro adaptativo desarrollado mas filtro de suavizado.	34
4.5. Análisis de perfil de objeto 3D reconstruido antes y después de aplicar filtro adaptativo desarrollado y suavizado desarrollado.	34
4.6. Imágenes de base de datos generada para entrenamiento de Red Neuronal Convolutiva (CNN). Imágenes a), e), i), c), g) y k) con ruido, e imágenes b), f) j), d), h) y l) filtradas.	35
4.7. Vista cercana del ruido de Moire procesado con la red neuronal convolutiva desarrollada (Multiresolution CNN Modified).	36
4.8. Reconstrucción de objeto 3D.	37
4.9. Análisis de perfil de objeto 3D reconstruido antes y después de pre-procesamiento con Multiresolution-CNN Modified.	37
4.10. Evolución de pérdida de entrenamiento y validación de los modelos entrenados seleccionados para comparación con el modelo propuesto.	39
4.11. Evolución de pérdida de los modelos entrenados seleccionados para comparación con el modelo propuesto.	40
4.12. Representación 2D de objetos 3D obtenidos con diferentes arquitecturas de CNN	41
4.13. Reconstrucción de objeto 3D obtenido con diferentes arquitecturas de CNN y objeto original reconstruido con PSP.	41
4.14. Representación 2D de objeto 3D obtenido con diferentes arquitecturas de CNN y objeto original reconstruido con PSP.	42
4.15. Análisis de perfil antes y después de procesamiento con redes entrenadas seleccionadas.	42
4.16. Reconstrucciones de objeto 3D obtenido con diferentes arquitecturas de CNN, objeto 3D original con ruido y objeto 3D original.	43
4.17. Evolución de pérdida de entrenamiento y validación de los modelos CNN entrenados para comparación con modelo propuesto.	45
4.18. Evolución de pérdida de entrenamiento y validación de los modelos CNN entrenados para comparación con modelo propuesto.	46
4.19. Representación 2D de objetos 3D obtenidos con diferentes arquitecturas de CNN y representación 2D original con ruido.	47
4.20. Reconstrucción de objeto 3D obtenido con diferentes arquitecturas de CNN	47
4.21. Reconstrucción de objeto 3D obtenido con diferentes arquitecturas de CNN y objeto original reconstruido con PSP.	48
4.22. Análisis de perfil antes y después de procesamiento con redes entrenadas seleccionadas.	48
4.23. Reconstrucciones de objeto 3D obtenido con diferentes arquitecturas de CNN, objeto 3D original con ruido y objeto 3D original.	49
4.24. Evolución de pérdida por entrenamiento y por validación de cada red CNN entrenada.	51
4.25. Evolución de pérdida por entrenamiento y por validación de cada red CNN entrenada.	52
4.26. Vista cercana de objetos 3D después de ser procesado con múltiples CNN's y objeto con ruido cuasi/periódico.	53
4.27. Vista cercana de objetos 3D después de ser procesado con múltiples CNN's y objeto con ruido cuasi/periódico.	54
4.28. Reconstrucción de objetos reales filtrados con modelo entrenado, parte 1.	55
4.29. Reconstrucción de objetos reales filtrados con modelo entrenado, parte 2.	56

Índice de Tablas

2.1. Tabla de autores con los antecedentes más relevantes.	9
3.1. Capas de convolución	29
3.2. Capas de deconvolución	29
4.1. Parámetros usados durante el entrenamiento de redes para comparación	38
4.2. Resultados del entrenamiento de redes para comparación	39
4.3. Métricas obtenidas a partir de objetos 3D resultantes de entrenamiento de diferentes arquitecturas CNNs.	44
4.4. Parámetros usados durante el entrenamiento de redes para comparación	44
4.5. Resultados del entrenamiento de redes para comparación	46
4.6. Parámetros usados durante el entrenamiento de redes para comparación	50
4.7. Resultados del entrenamiento de redes para comparación con mejores parámetros encontrados para cada modelo CNN.	51
4.8. Métricas obtenidas a partir de objetos 3D resultantes de inferencias de diferentes arquitecturas CNNs.	53

Introducción

Sensores y cámaras detectan el mundo en 2 dimensiones y sin profundidad, a diferencia de los humanos que perciben el mundo en 3 dimensiones y con profundidad, detectando de esta manera detalles del mundo que lo rodea.

Sin embargo, técnicas modernas permiten obtener información 3D de objetos a partir de los dispositivos mencionados, consiguiendo de esta manera observar el mundo que lo rodea con cierta precisión cercana a la realidad. Una de estas técnicas es la obtención de información 3D de objetos por medio de imágenes 2D usando perfilometría por cambio de fase (PSP) sobre objetos. Sin embargo, dicha técnica produce patrones de ruido en las imágenes conocido como ruido de Moire que afectan la precisión y reconstrucción final del objeto que se trata de reconstruir y la extracción de información 3D.

En esta tesis se plantea la atenuación con filtro usando técnicas clásicas para reducir la presencia de patrones de ruido de Moire, específicamente ruido cuasi/periódico obtenido durante la extracción y desenvolvimiento de fase(PSP), de imágenes para ser usados en reconstrucciones 3D obtenidos mediante perfilometría por cambio de fase(PSP). La metodología describe detalladamente el procedimiento utilizado para eliminar de manera exitosa el ruido cuasi/periódico. Las imágenes usadas son obtenidas sintéticamente mediante software *Blender* donde son capturadas mediante proyección de franjas con un deslizamiento de 120 grados, además del plano de referencia de uso para recuperar los mapas de fase y las imágenes que contienen la imagen original del objeto sin proyección de franjas y máscara de objeto que se desea reconstruir. Este trabajo propone además un filtro tradicional de procesamiento de imágenes y un filtro basado en una red neuronal convolucional profunda (Deep CNN) para ser usado como pre-procesamiento en la reconstrucción 3D de objetos mediante perfilometría de franjas.

1.0.1. Visión por computadora

El mundo como se nos presenta puede ser percibido en una amplia gama de formas y colores por nuestros ojos. Así podemos darnos cuenta de que el mundo que nos rodea se nos presenta en forma tridimensional con tamaño y profundidad variados. Sin embargo las computadoras que reciben esta información mediante sensores de luz como cámaras son incapaces de leer esta información ya que no detectan la profundidad y ni la forma en algunas situaciones de mala iluminación. Con ayuda de sistemas inteligentes de visión los computadores actuales han sido capaces de leer la información de imágenes para obtener información en 3D y ser capaces de reproducirlos tal y como lo hacen

los humanos para toma de decisiones. Con la intención de afrontar este desafío, se han desarrollado técnicas que permiten obtener toda la información disponible a partir de imágenes 2D como entrada.

1.0.2. Redes neuronales convolucionales

Modernas técnicas que permiten extraer la máxima cantidad de información disponible en imágenes 2D con ayuda de Inteligencia Artificial(I.A.) son la redes neuronales convolucionales(CNN). Estas están conformadas por capas de neuronas interconectadas que de acuerdo a la cantidad de capas con que se conforma una red neuronal recibe el nombre de red neuronal de aprendizaje profundo (Deep Learning) que en la practica son mas de dos capas, ya que las capas intermedias estan generalmente ocultas. Las redes neuronales convolucionales son capaces de procesar imágenes para obtener de ellas información mediante obtención de mapas de características así como reducción de la resolución de las imágenes de entrada para de esta manera obtener características específicas de dichas imágenes que permitan la clasificación, segmentación o restauración de imágenes.

1.0.3. Definición del problema

Actualmente, la generación de un objeto 3D por computadora a partir de imágenes 2D utilizando técnicas como perfilometría a tomado relevancia debido a las muchas aplicaciones posibles en diversas áreas, lo que ha abierto un nuevo campo de investigaciones para este fin. Sin embargo, la reconstrucción de objetos presenta aún problemas debido al ruido cuasi/periódico producido durante el procedimiento de adquisición de las imágenes. Este ruido es adquirido por el desplazamiento de franjas sobre el objeto que se desea reconstruir, ya que genera deformaciones sobre el objeto cuando encuentra zonas con geometría compleja o con sombras, entre otros.

Además, la proyección de múltiples patrones de franjas también genera interferencia, debido a que cuando se procesan en conjunto, se traslapan entre ellas, produciendo el ruido de Moire. Otro problema se produce cuando se intenta reconstruir un objeto tridimensional en movimiento, ya que la proyección de franjas presenta una mayor interferencia entre ellas, produciendo un mayor traslape entre las proyecciones y en consecuencia, mayor ruido cuasi/periódico en la reconstrucción del objeto tridimensional.

La obtención de medidas cercanas a los reales es un problema aún presente en la generación de objetos 3D por computadora debido a que son fuertemente afectados por el ruido presente en las imágenes utilizadas para tal fin, lo que genera un objeto final reconstruido, inexacto o poco confiable impidiendo su uso en aplicaciones donde la precisión puede ser un factor importante.

Las investigaciones actuales, aunque han mejorado, siguen presentando este problema en la reconstrucción de objetos 3D, por lo que los sistemas para eliminar el ruido periódico de las imágenes antes del proceso de generación del objeto 3D usando redes neuronales convolucionales (CNN) podría reducir el ruido sobre las imágenes antes de la reconstrucción del objeto 3D consiguiendo de esta manera una mayor precisión en la reconstrucción del objeto 3D por computadora.

1.0.4. Justificación

Actualmente, la obtención y reconstrucción de imágenes tridimensionales está en pleno desarrollo con los avances tecnológicos y metodológicos que se han alcanzado. Sin embargo, la fase de reconstrucción final del objeto tridimensional sigue presentando desafíos aún por resolver, como el ruido periódico y cuasi/periódico, además de los patrones de Moire producidos por el movimiento de los objetos, y por interferencia entre los píxeles de una pantalla y los píxeles del sensor

de la cámara, esto es porque el objeto final generado por computadora, presenta irregularidades que no son deseados, como imprecisiones cuando se realizan mediciones debido a que no se genera completamente el objeto por el ruido presente en las imágenes que se toman como modelo.

Los avances en el desarrollo de redes neuronales convolucionales para restauración de imágenes permiten reducir el ruido presente en imágenes antes de generar el objeto final, lo que supondría un avance en este campo, ya que se traduciría en una mejor precisión al obtener el objeto final reconstruido, además debido a que hacen uso de la Unidad de Procesamiento Gráfico (GPU) aumentaría de la velocidad de procesamiento lo que también provocaría una disminución en los tiempos de procesamiento de imágenes reduciendo también costos, haciendo posible su implementación en áreas de aplicación en los que actualmente se demandan una mayor precisión de objetos tridimensionales reconstruidos a partir de imágenes y en tiempo real.

La aplicación de objetos reconstruidos de manera tridimensional obtenidos con precisión podría tener aplicaciones en diferentes áreas como medicina, donde sería posible crear prótesis, piezas dentales, entre otros. Otra aplicación de interés tiene que ver con la generación de entornos virtuales o con digitalización de objetos de valor histórico delicados, ya que facilitaría la generación de objetos de formas irregulares y sin dañarlos, entre otros.

1.0.5. Hipótesis

Un filtro basado en aprendizaje profundo reduce el ruido periódico presente en imágenes adquiridas por perfilometría permitiendo una reconstrucción de objetos 3D por computadora más aproximados, comparables al estado del arte.

1.0.6. Objetivos

Objetivo general

Desarrollar e implementar un filtro de reducción de ruido periódico basado en aprendizaje profundo para la reconstrucción 3D de objetos con el objetivo de mejorar la exactitud.

Objetivos específicos

- Realizar un análisis del tipo de ruido periódico presente en imágenes obtenidas por perfilometría para conocer sus características.
- Proponer un filtro basado en una arquitectura CNN para reducir el ruido periódico de las imágenes antes de su reconstrucción.
- Realizar pruebas aplicando el filtro desarrollado a imágenes con ruido periódico para medir los resultados de la implementación y compararlo con otras metodologías del estado del arte.

Alcances

- Desarrollar un algoritmo que reduzca ruido de Moire presente en imágenes para su uso en reconstrucción 3D de objetos.
- Crear base de datos con imágenes que se usaran para experimentación.

- Proponer una arquitectura de Red Neuronal Convolutiva que reduzca ruido de Moire presente en imágenes.
- Realizar las pruebas y experimentos requeridos para concluir con el proyecto.

Limitaciones

- Tiempo limitado para la consecución de imágenes para entrenamiento de Red Neuronal Convolutiva.
- Falta de equipo adecuado para entrenamiento de Red Neuronal Convolutiva (CNN)

Antecedentes

2.1. Trabajos relacionados

Métodos de metrología óptica generan imágenes, como los patrones de franjas, haciendo de esta forma esenciales dichas imágenes para reconstrucción 3D. En la mayoría de los métodos interferométricos, una imagen es formada mediante la superposición de las proyecciones de referencia y el objeto a ser medido, con el que se obtiene un patrón de franjas del objeto al ser modulado por una función armónica. Como resultado se obtiene un contraste de zonas iluminadas y zonas oscuras

Las primeras técnicas para obtener mediciones 3D de objetos fue colocando dos rejillas interpuestas que formaban patrones de franjas de Moiré sobre un objeto pequeño. A esta técnica se le conocía como topografía Moiré[4].

Una propuesta diferente de medir objetos 3D fue la perfilometría de la transformada de Fourier, el cual era ajustable y automatizaba las mediciones, lo que le permitía distinguir de esta forma entre una depresión y una elevación de la forma del objeto, no requería asignaciones de orden marginal o determinación de centro marginal y tampoco necesitaba interpolación entre las franjas, ya que proporcionaba una distribución de altura de todos los elementos de la imagen sobre la imagen del objeto medido[5].

Avances tecnológicos permitieron usar proyectores que simulaban las franjas sobre los objetos de manera digital, con lo que se podían manipular más fácil la proyección de las franjas por la técnica Moiré. De esta manera, la franja proyectada podía ser generada de forma digital, permitiendo la proyección de patrones complejos de franjas. Una desventaja de los primeros proyectores a color era la proyección de luz sólida, siendo estos los colores RGB, provocando que cuando se proyectara el color gris fallaba el sistema. Además, los proyectores hacen un ajuste adicional a los patrones que se le envían mediante computador, por lo que se distorsiona previamente a la proyección sobre el objeto. Mejoras posteriores permitían la proyección de luz digital. Así, utilizando un proyector de luz infrarroja (Digital-Light Processing (DLP)), una cámara infrarroja CMOS de alta velocidad y una cámara a color, fue posible la obtención de mediciones de objetos en 3D sin necesidad de proyectar luz visible sobre los objetos, además del color para dar textura al objeto reconstruido. Todo esto en tiempo real e iluminación ambiental[6].

Otra técnica empleada en la medición de objetos 3D consiste en la aplicación de luz estructurada que es la iluminación activa de la escena con un diseño especial 2D de patrón de intensidad variable espacialmente. Esta iluminación es aplicada sobre una escena por un proyector y una cámara es usada para adquirir la imagen de la escena bajo la iluminación de luz estructurada. El principio de

las técnicas de imagen de superficie 3D de luz estructurada es extraer la forma 3D de los objetos basados en la información de la distorsión del patrón proyectado de luz estructurada [7] [8] [9].

Varias técnicas ha sido desarrolladas para extraer información 3D de objetos mediante Perfilometría de Proyección de Franjas, también conocido como Perfilometría de Cambio de Fase (PSP) y se especializan en la recolección de datos y análisis que pueden ser aplicados en situaciones donde se requieran mediciones precisas [10].

El más reciente avance es la utilización de software que permiten simular la proyección de franjas sobre objetos virtuales y realizar la captura de la imagen para la obtención de información 3D del objeto simulado mediante Perfilometría de cambio de fase.

2.1.1. Antecedentes de filtros para reducción de ruido en imágenes

Las primeras investigaciones para desarrollar filtros en el dominio espacial de las imágenes para reducir el ruido o contaminación lograron eliminarlos de manera limitada, ya que se encontró que estos filtros fallaban debido a que el ruido presente en las imágenes afectaba a toda la imagen, además de que, la reducción de ruido no era completa o se perdía información de la imagen [11].

La reducción y/o atenuación de ruido o contaminación en imágenes surgió desde que se pudieron conseguir imágenes por medios artificiales. Sin embargo, no fue hasta que se analizaron las fuentes que producían dicha contaminación, así como la manera en como se presentan digitalmente que no se comenzó a trabajar en una forma de eliminar ruido presente en imágenes. Con esto se comprobó que existían diferentes tipos de ruido o contaminación en las imágenes. Siendo de particular interés aquellos que aparecían con una periodicidad regular, ya que posteriormente se comprobó que se formaban siguiendo una función definida de tipo sinusoidal.

Una vez que se identificó como se formaba el ruido periódico o cuasi/periódico, se llegó a la conclusión de que analizando su espectro en el dominio de la frecuencia, se podía identificar fácilmente el ruido periódico, siendo este un ruido sinusoidal periódico producido por diferentes fuentes externas y por el mismo procedimiento de adquisición de información. Sin embargo, el ruido cuasi/periódico resulta ser más difícil de localizar debido a que se confunde o se mezcla con las características propias de la imagen, como se puede observar en las imágenes de la figura 2.1

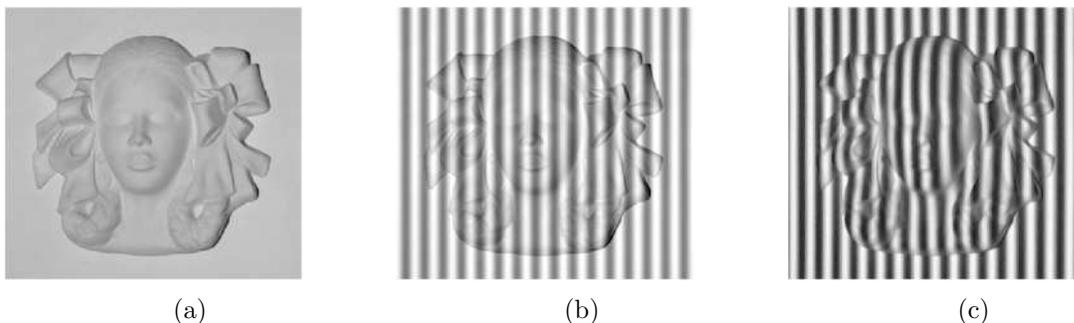


Figura 2.1: a) Imagen Original, b) Imagen original con ruido periódico y c) imagen original con ruido cuasi/periódico.

Sin embargo, aunque se identificaban claramente las regiones que ocasionaban este ruido y se aplicaba un filtro para suprimir o reducir el ruido presente, los costos computacionales eran altos.

Una vez que se detectaban regiones con ruido en imágenes contaminadas, se procedía a su eliminación o atenuación. De esta forma, la aplicación de un filtro de morfología suave (SMF)

propuesta por Zhen(Zhen, Zhong, Qi & Quinghua, 2004)[\[12\]](#) disminuía el ruido y mejoraba la calidad visual de la imagen, al reemplazar los píxeles de una imagen por el promedio de las salidas de proceso de dilatación y erosión suaves. El filtro de morfología suave optimizado (OSMF) es una variante del filtro SMF que utiliza un enjambre de partículas para optimizar el filtro SMF, sin embargo, las imágenes restauradas contenían un alto grado de distorsión así como de borrosidad por lo que resultaba insuficiente en eliminar o atenuar efectivamente el ruido periódico o cuasi/periódico en imágenes con alto grado de contaminación[\[13\]](#).

Investigaciones posteriores trataron la eliminación del ruido presente en imágenes contaminadas mediante su transformación al dominio de la frecuencia de dichas imágenes contaminadas [\[14\]](#). Al aplicar transformada de Fourier a una imagen contaminada, el ruido periódico o cuasi/periódico aparece como patrones repetitivos. De esta forma, las frecuencias del ruido de Moire se concentran como picos de diferente frecuencia perteneciente a un tipo distinto de ruido, dependiendo de la función sinusoidal con la que se conforma dicho ruido [\[15\]](#). Debido a que las frecuencias no deseadas producidas por el ruido periódico o cuasi/periódico se diferencian claramente de las otras frecuencias que componen la imagen, se vuelve relativamente fácil su detección, ya que generalmente aparecen con forma de estrella sobre la imagen en el dominio de la frecuencia. De esta forma, filtros basados en el dominio de la frecuencia mejoran la eliminación o atenuación del ruido periódico o cuasi/periódico al reemplazar o suprimir los píxeles con frecuencias no deseadas de las regiones que los contienen y que producen el ruido de Moire[\[16\]](#) [\[17\]](#). Diversos filtros basados en el dominio de la frecuencia fueron desarrollados debido al potencial que tenían para reducir y eliminar efectivamente el ruido periódico o cuasi/periódico en imágenes contaminadas. Así, por ejemplo, el filtro de muesca Gaussiano no solo era capaz de filtrar las frecuencias centrales de una región, sino también la de sus vecinos, por lo que aplicando algoritmos de detección de picos de frecuencia, era frecuentemente usado para reducir el ruido de Moire en imágenes contaminadas con este tipo de ruido[\[3\]](#). Otros filtros utilizados para el mismo fin como el filtro de muesca Gaussiano por ventanas (Windowed Gaussian Notch Filter)[\[18\]](#) y el filtro de muesca adaptativo óptimo (Adaptive Optimum Notch Filter) eran capaces de reducir y atenuar el ruido periódico o cuasi/periódico, sin embargo, su naturaleza no adaptable de detectar regiones con ruido limitaban su rendimiento[\[19\]](#).

Desde que se descubrió que el patrón de ruido de Moiré también se presentaba en microscopía de rayos x de transmisión de barrido (Scanning Transmission X-ray Microscopy (STXM)), y con ello introduciendo errores significativos en el análisis de imágenes tanto cuantitativos como cualitativos, además de la complejidad para evitar el patrón de ruido de Moiré durante la adquisición de imágenes, Wei, (2011), propuso la introducción de un método de post-procesamiento para el filtrado de ruido en imágenes STXM. El método incluye una detección semiautomática de picos presentes en la amplitud de espectro de Fourier[\[20\]](#). Una vez localizados las regiones afectadas por ruido de Moire, Alvarado (Alvarado, 2020) propone un filtro de cruz, que suprime las frecuencias de ruido localizadas a lo largo de los ejes vertical y horizontal de las imágenes en el dominio de la frecuencia, consiguiendo con ello atenuar exitosamente el ruido cuasi/periódico en imágenes obtenidas mediante proyección de franjas[\[21\]](#).

Filtros con umbral adaptativo basados en el dominio de la frecuencia como el filtro ATBF (Adaptative Threshold Based Filter) propuesto por Varghese(Varghese, 2016), es efectivo para reducir el ruido periódico mediante la determinación adaptativa de una función de umbral para la identificación de áreas con un pico de ruido en el dominio de la frecuencia de una imagen. Después las frecuencias no deseadas son difuminados por un filtro de mínimos para una restauración en el dominio de la frecuencia de las imágenes. La imagen restaurada en el dominio de la frecuencia se

le aplica la transformada de Fourier inversa y operaciones de cambio para reconstruir la imagen final al dominio espacial[22]. Sin embargo, no es completamente efectivo en imágenes que contienen ruido cuasi/periódico dada la naturaleza de dicho ruido.

Filtro de suavizado espacial se han usado para difuminar imágenes, logrando de esta forma reducir o atenuar el ruido periódico o cuasi/periódico presente en imágenes digitales. De esta forma, aplicando filtros lineales, se puede eliminar el ruido en imágenes contaminadas. Al aplicar un filtro de suavizado espacial, dicho filtro consiste en simplemente realizar un promedio de pixeles vecinos y reemplazar un pixel con dicho valor[3]. Otras técnicas aplicadas al dominio espacial para atenuar el ruido periódico o cuasi/periódico de imágenes contaminadas incluyen algoritmos que remueven la textura de imágenes contaminadas, ya que contiene componentes de ruido periódico o cuasi/periódico de alta frecuencia[23][24][25].

Recientes técnicas hacen uso de redes neuronales convolucionales después de demostrar que eran capaces de clasificar[26] y reconocer imágenes[27][28], además de que han demostrado su potencial en áreas de visión por computadora de bajo nivel y tareas de procesamiento de imagen. Tareas como imágenes con superresolución[29], reconstrucción de imágenes mediante muestras cromáticas incompletas[30], eliminación de ruido[30] y restauración de imágenes[31], son aplicaciones en constante evolución. Usando una red neuronal convolucional profunda (DnCNN), Zhang, 2017, consigue remover el ruido blanco de imágenes contaminadas en diferentes niveles utilizando estrategias de eliminación de ruido de aprendizaje residual, limpiando imágenes dentro de las capas ocultas del modelo DnCNN[32]. Sun(Sun, Yu, & Wang, 2018)[33] propone una red neuronal convolucional profunda para eliminar el ruido de Moire de imágenes capturadas con cámaras fotográficas de celulares.

Técnicas de perfilometría de superficie y preprocesamiento de imágenes con CNN para eliminación de ruido están en constante desarrollo debido a la gran demanda que se tiene en el campo científico por su gran exactitud y rapidez que se consiguen, aproximándose al objeto real. Sin embargo, aún existe el desafío de conseguir superficies complejas como el rostro humano, entre otros.

2.2. Estado del arte

En la tabla 2.1 se muestran los antecedentes recopilados más relevantes que se han realizado sobre técnicas para reducir el ruido periódico en imágenes.

La reconstrucción 3D de objetos es una tarea complicada que se realiza con el fin de obtener objetos digitales que pueden ser usados en muchas aplicaciones. Los modelos 3D no deben ser en muchos casos solo visualmente similares al objeto real, sino también deberían ser precisos desde un punto de vista geométrico. Algunas técnicas de escaneo permiten reconstruir objetos a partir de escaneos de objetos de manera digital. Para reconstrucción de objetos 3D a partir de imágenes existen diferentes técnicas, las cuales pueden ser clasificadas en 2 grupos: técnicas por contacto y técnicas sin contacto[1]. La figura 2.2 muestra las diferentes técnicas existentes de contacto y no contacto para reconstrucción de objetos 3D.

Las técnicas por contacto tienen el inconveniente de que pueden ser destructivas y ocasionar daño al objeto. Las técnicas sin contacto, por otro lado, solo toman escaneos del objeto, por lo que el daño invasivo con el objeto es mínimo. Estos se dividen a su vez en reflectivas y transmisivas. Las técnicas reflectivas a su vez se dividen en ópticas y no ópticas. La figura 2.3 muestra la clasificación de técnicas ópticas.

Diferentes técnicas ópticas han sido implementados para reconstruir objetos en 3D de manera

Tabla 2.1: Tabla de autores con los antecedentes más relevantes.

Autor(es)	Técnica	Uso de Técnica	Aportación
Wei, Z., (2012)	Filtro Gaussiano de la mediana.	Remover ruido periódico	Detección y corrección de distorsiones en el espectro en imágenes causados por ruido periódico.
Varghese, J., (2016)	Filtro de dominio de frecuencia basado en umbral adaptativo.	Reducción de ruido periódico presente en imágenes	Identificación de frecuencias con ruido en dominio de la frecuencia en imágenes y restauración de dichas frecuencias no deseadas.
Van der Jeught S, (2016)	Perfilometría.	Estado del arte	Dar a conocer los métodos más comúnmente utilizados para la reconstrucción y la medición de superficies 3D.
Sun, Y., (2018)	Uso de redes neuronales convolucionales multi-resolución.	Remoción de patrones de Moiré en imágenes	Reducción de patrones de Moiré más significativas comparados con otros métodos.
Ji, Z., (2004)	Filtro de morfología suave.	Reducir el ruido periódico presente en el procesamiento de imágenes	Diseño e implementación en computación mas eficiente que otros métodos convencionales en el dominio de la frecuencia.
Nah, S., (2017)	Aprendizaje residual y normalización por lotes de DeepCNN.	Eliminación de ruido en imágenes	Alta efectividad para eliminar ruido e implementación eficiente haciendo uso de GPU (Graphics Processing Unit).
Alvarado Escoto L. A. (2020)	Filtro bilateral	Procesamiento de imágenes para reconstrucción de objetos 3D	Reconstrucción de objetos mas suaves y mejor estimación de alturas de los objetos reconstruidos.

precisa y similar al objeto real mediante adquisición de la información del objeto por medios ópticos. Así se han desarrollado sistemas de visión estéreo, luz estructurada y tiempo de vuelo; sin embargo, la técnica de luz estructurada ha sobresalido por sobre las demás técnicas debido a su simplicidad y velocidad de procesamiento[6]. La extracción de información 3D mediante técnicas de luz estructurada se basa en las técnicas de codificación de luz proyectada y proyección de patrón de franjas sinusoidal, en el cual la profundidad del objeto es extraído mediante la deformación de un patrón de franjas proyectado sobre un objeto[34].

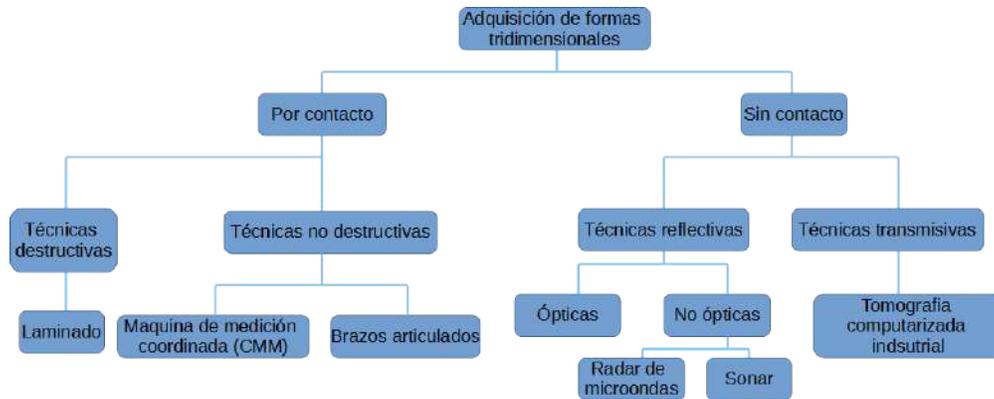


Figura 2.2: Taxonomía de las técnicas de adquisición 3D [1].

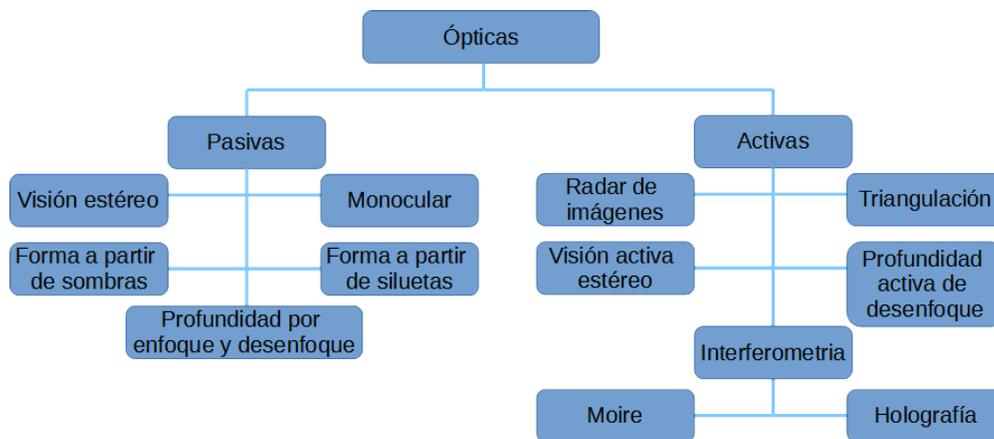


Figura 2.3: Clasificación de las técnicas de adquisición óptica [1].

2.3. Principio de perfilometría de proyección de franjas y desenvolvimiento de fase.

La idea principal de perfilometría mediante proyección de franjas es obtener un mapa de alturas de un objeto dado como un mapa de patrón de franjas deformado. Al mismo tiempo se obtiene el contorno del objeto, permitiendo de esta forma visualizar características físicas del objeto [34]. Como se observa en la figura 2.4, un sistema básico de perfilometría por proyección de franjas consiste en una cámara, un proyector y el patrón definido de franjas que se proyectara sobre un objeto, el objeto y el mapa de referencia de dicho objeto que es simplemente la proyección de franjas sin el objeto.

Diferentes patrones pueden ser usados para la proyección de franjas, sin embargo, los más usados son barras verticales que pueden tener una disposición diferente. La figura 2.5 muestra diferentes vistas de la proyección de franjas representadas por barras.

El algoritmo de cambio de fase de N-pasos (N-Step) es un método conocido por su insensibilidad a la luz ambiental y reflectividad de la superficie [35], donde una serie patrones con deslizamiento de fase son proyectados con un cambio de fase obteniendo con ello un conjunto de imágenes que depende del número de pasos siendo estos de 3, 4, 8 o 12 pasos entre otros (N-Step). Los patrones

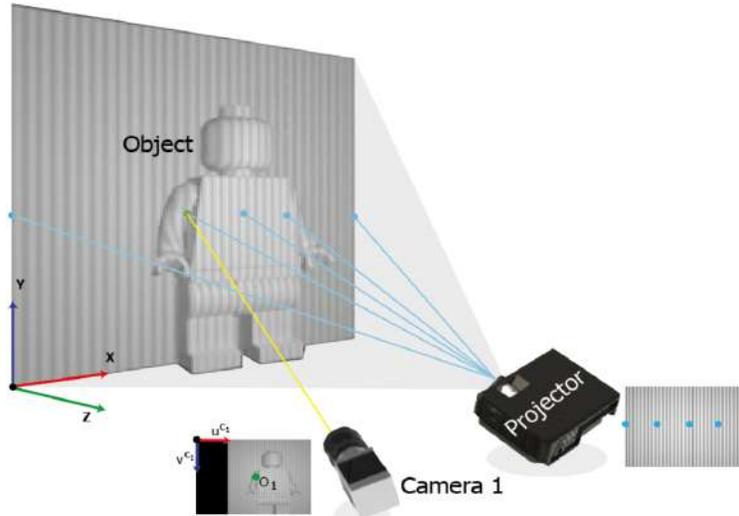


Figura 2.4: Sistema básico de perfilometría de proyección de franjas.

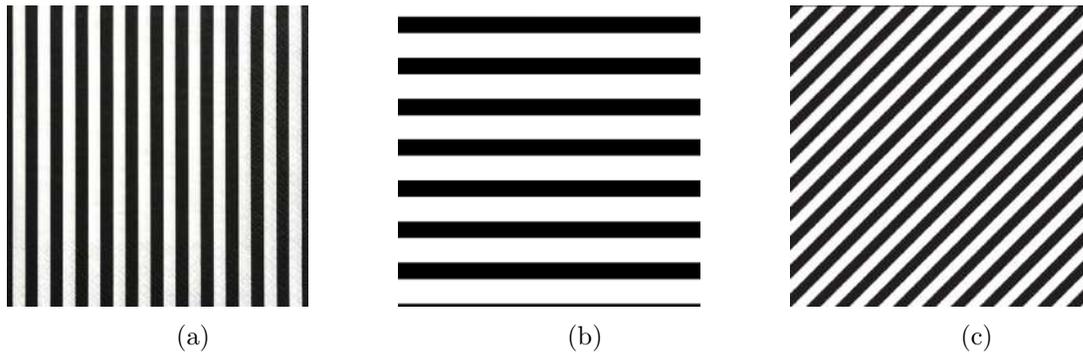


Figura 2.5: Diferentes patrones de barras usados en perfilometría de proyección franjas.

de franjas pueden ser expresados teóricamente en una imagen como la ecuación [2.1](#):

$$I(x, y) = a(x, y) + b(x, y)\cos(\phi(x, y)) \quad (2.1)$$

Existen varias maneras de extraer la información 3D de un objeto basado en el análisis de proyección de franjas tales como deslizamiento de fase y transformada de Fourier. Entre las técnicas más comunes usados para la extracción de información 3D se encuentran: Perfilometría, transformada wavelet (Wavelet Transform Profilometry (WFP)), (Spatial Filtered Profilometry (SFP)) y Perfilometría por Transformada de Fourier (Fourier Transform Profilometry (FTP)) siendo este último la más comúnmente usada cuando se tiene una única imagen de entrada. En FTP, un patrón sinusoidal de Ronchi se proyecta sobre la superficie de un objeto. Entonces la profundidad del objeto es codificado mediante un patrón de franjas deformado que puede ser decodificado usando la transformada de Fourier filtrando en el dominio espacial y usando la transformada inversa de Fourier, teniendo como ventaja, evitar la interpolación de franjas, ya que se obtiene una distribución de altura en cada pixel en todo el campo de cálculo [\[36\]](#).

Los patrones de deslizamiento de fase proyectados para 3 pasos (3-Step) quedan como se muestra en las ecuaciones [2.2](#), [2.3](#) y [2.4](#).

$$I_{L0} = A_L + B_L \cos(\phi_L) \quad (2.2)$$

$$I_{L0} = A_L + B_L \cos(\phi_L + 2\pi/3) \quad (2.3)$$

$$I_{L0} = A_L + B_L \cos(\phi_L + 4\pi/3) \quad (2.4)$$

Con el algoritmo de deslizamiento de fase, la fase envuelta ϕ para N-Pasos (N-Step) [37](#) puede ser obtenido mediante la ecuación [2.5](#) por el método de mínimos cuadrados.

$$\phi_L = \operatorname{artan} \frac{\sum_{n=0}^{N-1} I_{cn} \sin(2\pi n/N)}{\sum_{n=0}^{N-1} I_{cn} \cos(2\pi n/N)} \quad (2.5)$$

Entonces la fase envuelta ϕ usando el método de 3 pasos (3-Step) puede ser calculada con la ecuación [2.6](#).

$$\phi_L = \operatorname{artan} \frac{\sqrt{3}(I_{L1} - I_{L2})}{2(I_{L0} - I_{L1} - I_{L2})} \quad (2.6)$$

Dada la naturaleza de la función arctan, los valores extraídos oscilarán entre $[-\pi, +\pi]$, es posible que la fase real se encuentre en intervalos más grandes que 2π dando como resultado una fase recuperada con discontinuidades artificiales.

La fase absoluta Φ_L y la fase envuelta ϕ_L satisfacen la siguiente relación:

$$\Phi_L = \phi_L + 2k\pi \quad (2.7)$$

donde k es el orden de periodo, $k \in [0, N_L - 1]$ y N_L denota el número de franjas proyectadas en el plano marginal del sistema.

El mapa de fase obtenido contiene saltos de fase en píxeles adyacentes desde $+\pi$ a $-\pi$ y viceversa, por lo tanto, es necesario conectar los saltos de fase para obtener una distribución física final. La fase envuelta puede expresarse como la ecuación [2.8](#) donde $x(n)$ es la fase continua original, $W[]$ en el operador de la fase y $x_w(n)$ es la fase envuelta.

$$x_w(n) = W[x(n)] \quad (2.8)$$

El desenvolvimiento de fase es un proceso que determina la integral múltiple desconocida de π que será sumado a cada pixel de la fase envuelta previamente adquirida para hacer la señal de la fase continua en el dominio de la frecuencia. Removiendo todas las discontinuidades artificiales de 2π se obtiene la fase original después de aplicar la función de arctan, proceso que es realizado mediante la comparación de los píxeles vecinos de un pixel dado, y sumando o restando 2π para obtener la fase relativa entre ambos píxeles en el rango de $-\pi$ a $+\pi$. Sin embargo, el proceso puede ser difícil debido a la presencia de sombras, modulaciones de franjas bajas, discontinuidades de las franjas, ruido en las imágenes entre otros [38](#).

2.4. Patrón de Moire

Cuando 2 patrones similares repetitivos de líneas, círculos o puntos se sobreponen una sobre la otra sin alineación, aparece un nuevo patrón dinámico llamado ruido de Moire. El ruido de Moire puede modificar la forma y frecuencia de sus elementos cuando se mueven relativamente uno contra el otro, degradando de esta forma la calidad visual de una imagen, como se puede observar en las imágenes de la figura [2.1](#)[\[33\]](#). Se puede observar en la figura [2.1b](#) el patrón periódico que presenta la imagen y como se degrada la calidad visual de la misma, mientras que la figura [2.1c](#) se aprecia que el patrón es cuasi-periódico, ya que las franjas que muestra la imagen se adapta al objeto mismo, teniendo como resultado una mayor degradación visual de la imagen. Durante años se han desarrollado técnicas que reduzcan este patrón de Moire debido a la demanda de imágenes limpias, claras y de alta resolución. Varias de esas técnicas operan sobre el dominio de la frecuencia de las imágenes, analizando su espectro de amplitud y detectando picos de alta frecuencia. Otra técnica es la descomposición de matriz dispersa para el tratamiento de patrones Moiré[\[21\]](#). Otras aproximaciones más recientes hacen uso de redes neuronales convolucionales(CNN). En PSP, los patrones de Moire aparecen debido a la naturaleza del patrón de franjas usado y puede ser difícil controlar su aparición durante la adquisición de las imágenes. Por lo tanto, un post-procesamiento es realizado para remover o reducir el patrón de Moire siendo procesado normalmente sobre el dominio de la frecuencia de la imagen mediante la corrección de los componentes alterados por el ruido en el espectro de amplitud, consiguiendo de esta manera objetos reconstruidos en 3D más suaves, precisas y aproximadas al objeto real[\[20\]](#).

Metodología

3.1. Perfilometría por cambio de fase

El método por cambio de fase para obtener información de un objeto 3D es uno de los métodos ópticos que consigue tener menos error respecto del objeto original cuando se compara con otras técnicas. Este método consiste en la proyección de franjas sobre un objeto usando un proyector y una cámara para obtener imágenes en diferentes posiciones para capturar la modulación o distorsión de dichas franjas con la forma del objeto, repitiendo el proceso con un desplazamiento de las franjas proyectadas sobre el objeto.

Algoritmo de 3 pasos (three-step)

Uno de los algoritmos más usados en la perfilometría de cambio de fase es el método de 3 pasos (three-step). El método proyecta sobre el objeto 3 patrones de franjas. Estos patrones son descritas mediante las ecuaciones [3.1](#), [3.2](#) y [3.3](#).

$$I_1 = I'(x, y) + I''(x, y) \cos(\phi(x, y)) \quad (3.1)$$

$$I_2 = I'(x, y) + I''(x, y) \cos(\phi(x, y) + \alpha) \quad (3.2)$$

$$I_3 = I'(x, y) + I''(x, y) \cos(\phi(x, y) + 2\alpha) \quad (3.3)$$

donde $I'(x, y)$ es la intensidad, $I''(x, y)$ es la intensidad de modulación, $\phi(x, y)$ es la fase verdadera y α es el desfase igual a $2\pi/3$ [\[39\]](#) [\[40\]](#).

3.2. Adquisición de imágenes

Para obtener las imágenes con la proyección de franjas se desarrolla un entorno de emulación desarrollado en *Blender*, que es un software de uso libre para cualquier propósito, ya sea comercial

o educativo. Para la extracción y generación de figuras 3D se utilizaron figuras desarrolladas por profesionales en el campo y que pueden ser obtenidos de páginas web como *TurboSquid*. *TurboSquid* es usado por profesionales y desarrolladores de todo el mundo y fue creado con la intención de ahorrar tiempo en el desarrollo de modelos 3D grandes y complejos, permitiendo aprovechar el tiempo en otras áreas de desarrollo.

El sistema utilizado en software *Blender* consiste en elementos como cámaras, objetos 3D y luces. Con las luces se emula las franjas que se proyectan sobre los objetos simulando el sistema de perfilometría por proyección de franjas que consiste en un proyector que es representado por una lámpara con configuración mostrada más adelante, una cámara con una longitud de 28 mm con una lente de tipo "Perspectiva" en Configuración de Cámara como se muestra en la figura 3.1 donde P es el centro de la proyección del proyector, $C1$ es el centro de imágenes de la cámara, D es un punto arbitrario del objeto de prueba y el área efectiva de proyección de 15.4 mm es representado por l_0 . La distancia d entre la cámara y el proyector es de 3 mm y el plano de referencia es colocado frente al proyector a aproximadamente 15 mm representado por l . El entorno de emulación es realizando en *Blender* version 2.95.5. [2] [2].

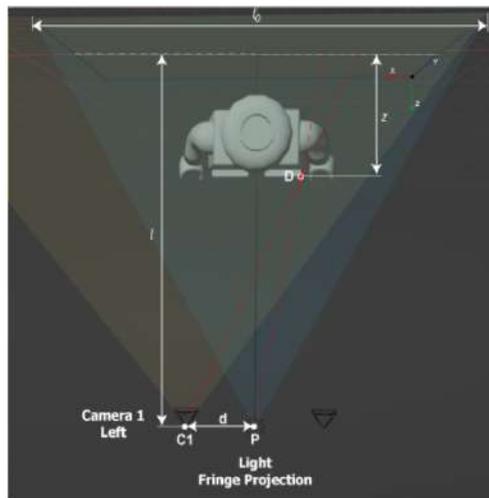


Figura 3.1: Trayectoria óptica de la perfilometría de medición de fase en el entorno emulado [2].

El árbol de nodos generados crea un plano de proyección como se muestra en la figura 3.2 seguido de un bloque llamado CLIP donde se generan los límites de la proyección de las lámparas a un área específica. Debajo de cada bloque anterior tenemos un bloque llamado SINE que genera la proyección de franjas, además de ser el bloque donde se puede manipular el cambio de fase de acuerdo al número de pasos que se implementara en este caso de 3 pasos(3-Step) [2].

Los objetos virtuales que se usaron pueden ser encontrados en el sitio *TurboSquid*, pero también pueden ser encontrados en base de datos [41] tales como ModelNet, ShapeNet, ABC, Thingi10K, etc., donde una variada colección de objetos desde simples a complejos pueden usarse para adquirir las imágenes con proyección de franjas sobre los objetos, como se muestra en los modelos de la figura 3.3 [2].

Con el sistema de emulación de proyección de franjas se obtienen imágenes con una resolución de 640 píxeles de ancho por 480 píxeles de alto y la generación de cada imagen renderizada toma un promedio de 1 segundo que puede variar debido a la complejidad del objeto. Las imágenes

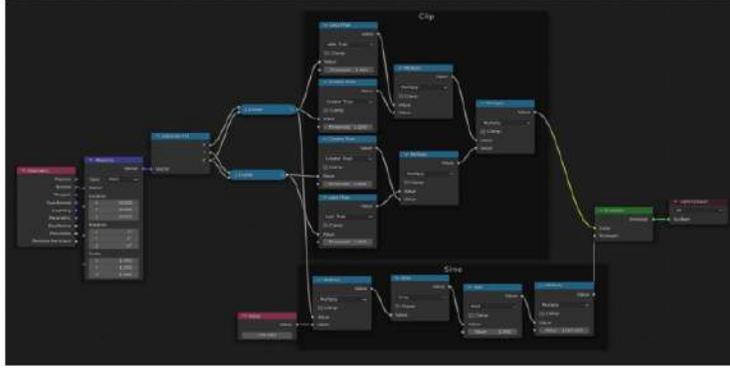


Figura 3.2: El árbol principal de nodos de composición de este sistema *Blender* [2].



Figura 3.3: Modelos del sitio *TurboSquid* [2].

obtenidas consisten en un conjunto de 3 imágenes con la proyección de franjas con deslizamiento de fase de $2\pi/3$ sobre el objeto y 3 con la proyección de imágenes si objeto para obtener la referencia, una(1) imagen de GroundTruth y una(1) imagen máscara del objeto para obtener una región de interés sobre el objeto. De esta manera se obtienen 8 imágenes por cada escena que se monta con el sistema.

3.2.1. Extracción de fase y desenvolvimiento de fase

Una vez obtenidas las imágenes con las franjas proyectadas del objeto y de referencia, se obtiene el mapa de fase absoluta con la ecuación [3.4] usando el método de 3 pasos (3-Step).

$$\phi(x, y) = \tan^{-1} \left(\sqrt{3 \frac{I_3(x, y) - I_1(x, y)}{2I_2(x, y) - I_1(x, y) - I_3(x, y)}} \right) \quad (3.4)$$

Las figuras [3.5] muestran un ejemplo de mapa de fase extraído usando la ecuación [3.4]

El desenvolvimiento de fase es el paso más importante en la reconstrucción 3D. Se han propuesto diversos métodos para realizar esta tarea, sin embargo, en el presente trabajo se utilizó el algoritmo PUMA o cortes gráficos (Cuts Graph) [42]. En este algoritmo, la minimización de energía se logra mediante una secuencia finita de minimizaciones binarias, cada uno logrado de manera eficiente por un flujo máximo/mínimo de corte en ciertos gráficos. El uso de algoritmo PUMA aunque

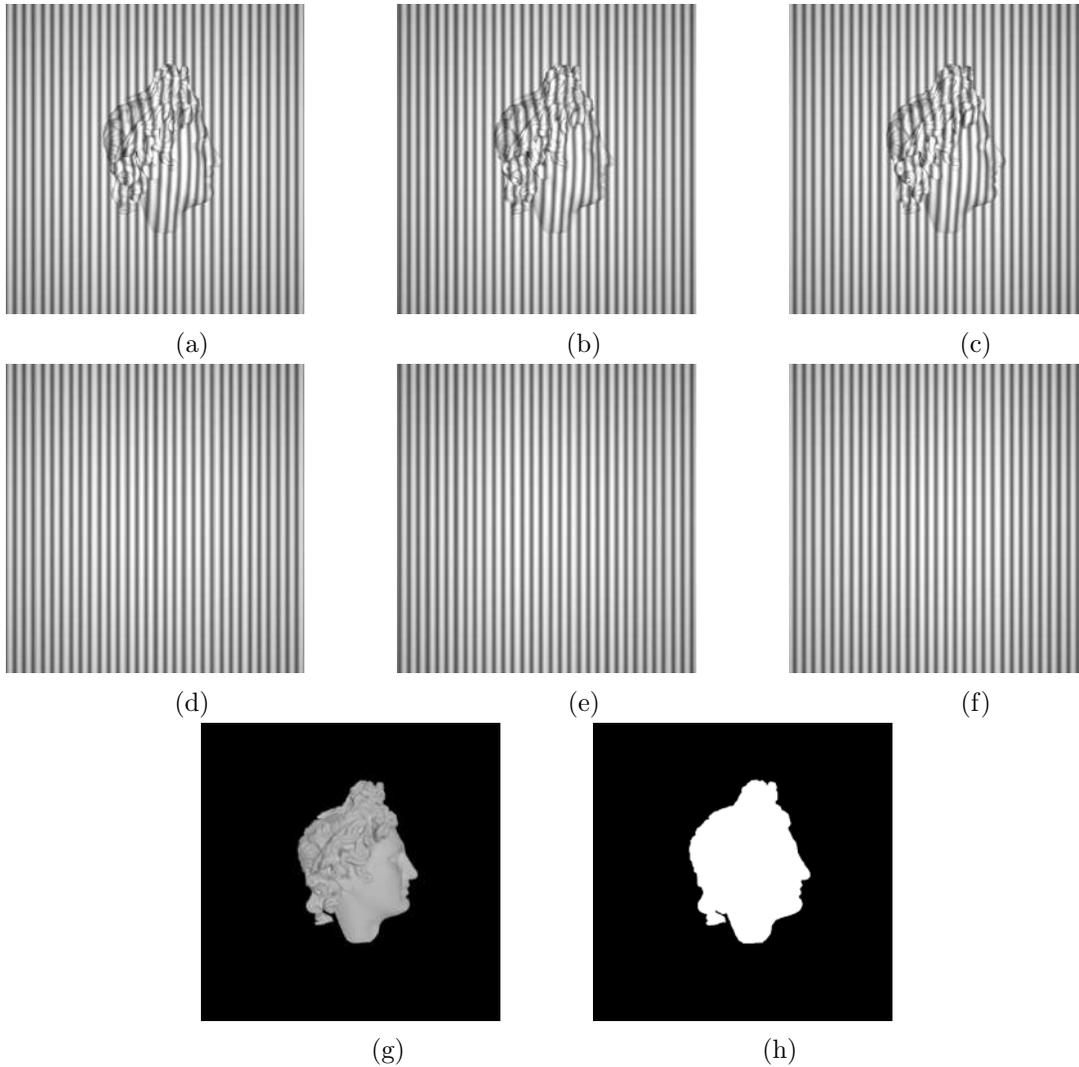


Figura 3.4: Conjunto de imágenes obtenidos por escena: a), b), c) proyección de franjas con objeto y deslizamiento de fase de $2\pi/3$, d), e), f) proyección de franjas de referencia y deslizamiento de fase de $2\pi/3$, g) Groundtruth, h) Mascara con región de interés.

tomaba tiempo obtener la fase desenvuelta, demostró tener el mejor desempeño para obtener mejor información 3D del objeto de estudio.

3.3. Filtrado de imágenes

El mapa absoluto obtenido de las imágenes mediante proyección de franjas muestra un patrón de ruido cuasi/periódico persistente en todas las imágenes obtenidas. Este ruido es producido cuando 2 o más patrones de franjas periódicos se sobreponen una sobre la otra y es completamente normal que estén presentes en los métodos de deslizamiento de fase. Por lo tanto, como se usan patrones de franjas deslizados para obtener mapas de fase de superficie, estos patrones de ruido periódico

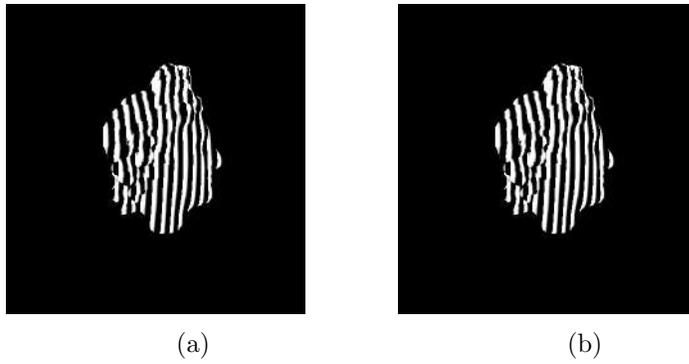


Figura 3.5: Mapas de fase objeto y de referencia.

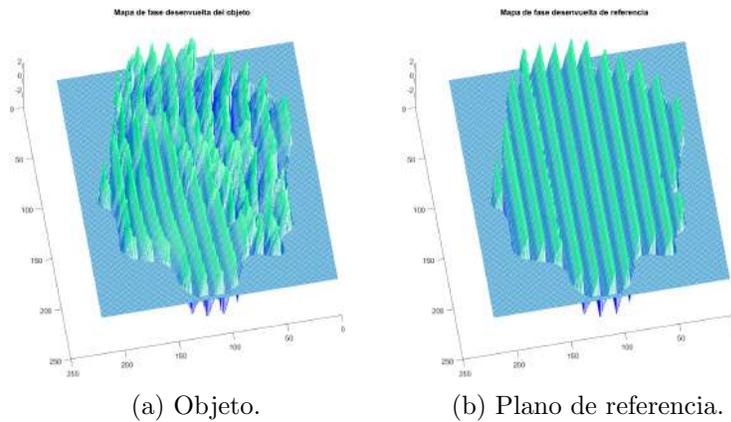


Figura 3.6: Representación 3D de mapas de fase desenvueltos de objeto y de referencia.

o cuasi/periódico (Moire) tienden a estar presentes durante todo el proceso de Perfilometría por Deslizamiento de Fase, desde que se obtienen las imágenes hasta que se obtiene el mapa de fase absoluto. El ruido cuasi/periódico es mostrado en la figura [3.7](#)

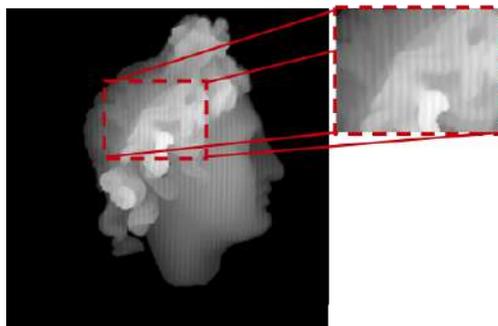


Figura 3.7: Mapa de fase absoluta obtenida mediante la resta de mapa de fase de objeto y de plano de referencia. Se aprecia el ruido cuasi periódico que afecta la reconstrucción 3D del objeto.

Este ruido reduce considerablemente la calidad de las reconstrucciones y provoca estimaciones de altura que pueden ser no consistentes o poco precisas. Por esta razón, se requiere un procesa-

miento de la imagen obtenida y contaminada que permita reducir dicho ruido presente. Debido a la dificultad que supone tratar el ruido durante la adquisición de las imágenes o durante el procesamiento para la obtención del mapa de fase absoluto, se propone un paso de post-procesamiento que consiste en 2 pasos: Proponer un algoritmo que atenúe el ruido presente en las imágenes y crear una base de datos con este algoritmo, y procesar mediante una red neuronal convolucional(CNN) las imágenes procesadas mediante el algoritmo propuesto, esto con el fin de reducir los tiempos de procesamiento de las imágenes afectadas por ruido cuasi/periódico.

3.3.1. Filtro de umbral adaptable en dominio de la frecuencia y suavizado en dominio espacial

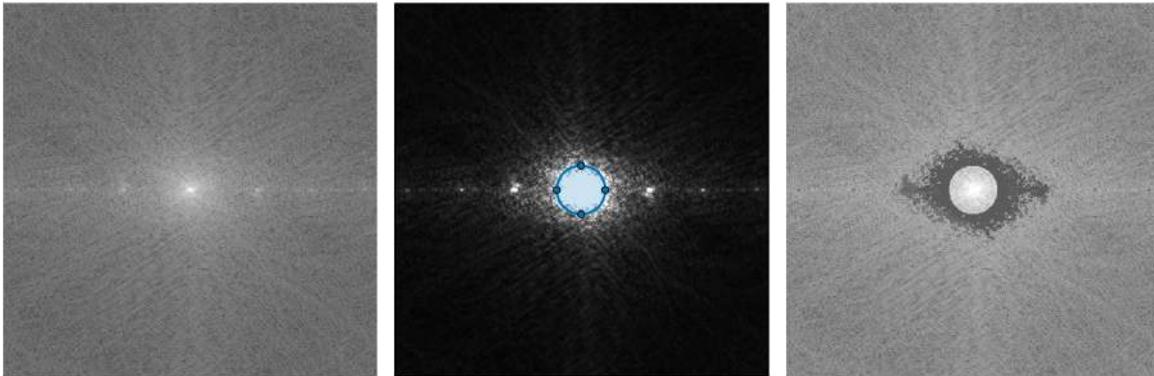
El desarrollo de un filtro que permita atenuar el ruido de Moire, específicamente el ruido cuasi/periódico, responde a la necesidad de obtener reconstrucciones 3D de alta calidad, por lo que técnicas para el tratamiento de reducción o eliminación del ruido cuasi/periódico en imágenes han ido desarrollándose a lo largo de los años. Así han surgido diversos métodos que tratan de eliminar el ruido de Moire trabajando tanto en el dominio espacial de la imagen como en el dominio de la frecuencia. Bajo esta premisa, Liu(Liu, Yang, & Yue, 2015)[\[43\]](#) propuso un método de eliminación de patrón Moiré a través de descomposición de matriz dispersa y de rango bajo, sin embargo, esta técnica solo se utiliza exclusivamente cuando los patrones de ruido periódico están bien definidos. Por otro lado, se ha demostrado que el tratamiento del ruido periódico en el dominio de la frecuencia de una imagen contaminada puede dar resultados bastante buenos, de esta forma Varghese(Varghese, 2016)[\[22\]](#) propone un filtro de umbral adaptable que trabaja en el dominio de la frecuencia de la imagen que se desea eliminar o atenuar el ruido periódico. De esta forma reemplaza los píxeles con frecuencias no deseados con los valores de las frecuencias de la media de sus píxeles vecinos, tomando en cuenta un umbral para evitar reemplazar frecuencias válidas. Sin embargo, dicho umbral es demasiado alto para algunos casos donde se presenta el ruido de Moire presenta patrones más irregulares, como los que se presentan cuando el ruido que afecta la imagen es cuasi/periódico. Por otro lado, Alvarado (Alvarado, 2020)[\[21\]](#) propone utilizar un filtro de cruz sobre la imagen en el dominio de la frecuencia, con lo que consigue reducir considerablemente el ruido cuasi/periódico en imágenes obtenidas mediante PSP, obteniendo de esta forma reconstrucciones más suaves y mejores estimaciones de altura en los objetos 3D reconstruidos.

Recientes técnicas hacen uso de redes neuronales convolucionales para eliminar el ruido de Moire. Sun(Sun, Yu, & Wang, 2018)[\[33\]](#) propone una red neuronal convolucional multi-resolución para eliminar el ruido de Moire de imágenes capturadas con cámaras fotográficas de celulares. Sin embargo, dicho patrón de ruido es muy diferente del patrón de ruido obtenido mediante perfilometría de proyección de franjas, por lo que su uso resulta inefectivo para atenuar el ruido de Moire.

En esta tesis se propone un filtro que atenúe el ruido cuasi/periódico en el dominio de la frecuencia en imágenes generadas por perfilometría de franjas, para de esta manera generar una base de datos de imágenes con el cual entrenar una red neuronal convolucional propuesta. Esto con el fin de realizar un preprocesamiento de imágenes afectadas con ruido en un tiempo reducido como parte de una metodología para la reconstrucción 3D de objetos.

Un filtro de umbral adaptable, además de un filtro de suavizado, es usado para atenuar el ruido presente en las reconstrucciones 3D mediante la atenuación de los píxeles con frecuencias no deseadas con la media de sus píxeles vecinos. Ya que un patrón de franjas verticales es usado para el análisis de franjas, los componentes de ruido normalmente se encontrarían a lo largo del eje horizontal cuando se analiza la imagen en el dominio de la frecuencia. Sin embargo, dado

que las franjas proyectadas sobre el objeto adoptan la forma del mismo, dicho patrón de franjas se distorsiona, por lo que el patrón de ruido que se presenta es cuasi/periódico, por lo tanto, se propaga por todo el espectro de la imagen. Un filtro de umbral adaptable se usa para reemplazar directamente los píxeles con las frecuencias corruptas por la media de sus píxeles vecinos, obteniendo de esta forma la frecuencia correspondiente, sin el ruido cuasi/periódico. La figura 3.8a muestra un ejemplo de una imagen en el dominio de la frecuencia con ruido cuasi/periódico en forma de estrella. La figura 3.8b muestra la misma imagen en dominio de la frecuencia con contraste ajustado que resalta prácticamente las frecuencias no deseadas de la imagen. Los píxeles de la región central se excluyen debido a que contienen la mayor información de la imagen, por lo que no son parte del proceso de filtrado. La imagen en la figura 3.8c muestra la imagen original en el dominio de la frecuencia, pero con las frecuencias no deseadas reemplazados cuando se aplica el filtro de umbral adaptable.



(a) Imagen en dominio de frecuencia con ruido cuasi/periódico visible. (b) Frecuencias no deseadas resaltadas mediante aplicación de contraste a imagen, excluyendo región central. (c) Imagen en dominio de frecuencia después de aplicar filtro de umbral adaptable.

Figura 3.8: Filtro de umbral adaptable.

Dado que el filtro de umbral adaptable trabaja en el dominio de la frecuencia, la imagen que se procesa es convertida a escala de grises, de esta manera se transforma al dominio de la frecuencia mediante transformada rápida de Fourier, después de aplicar el filtro, se reconvierte nuevamente al dominio espacial donde un filtro de suavizado es aplicado para atenuar el ruido residual. La figura 3.9 muestra los pasos para aplicar el filtro de umbral adaptable y filtro de suavizado.

Descripción de algoritmo desarrollado

El algoritmo propuesto es una variante del algoritmo ATBF (Adaptive Threshold Based Frequency) creado por Varghese (Varghese, 2016) [22] que convierte la imagen contaminada con ruido de cuasi/periódico al dominio de la frecuencia mediante la aplicación de la transformada rápida de Fourier para atenuar el ruido cuasi/periódico mediante la detección de las regiones que lo presentan, reemplazando los píxeles de las regiones localizados con la media del valor de sus píxeles vecinos. Para esto resalta las regiones con ruido y facilitando la detección de píxeles con frecuencias no deseadas. Sin embargo, las frecuencias no deseadas obtenidas mediante proyección de franjas se encuentran generalmente fuera de la región central de la imagen en el dominio de la frecuencia, por

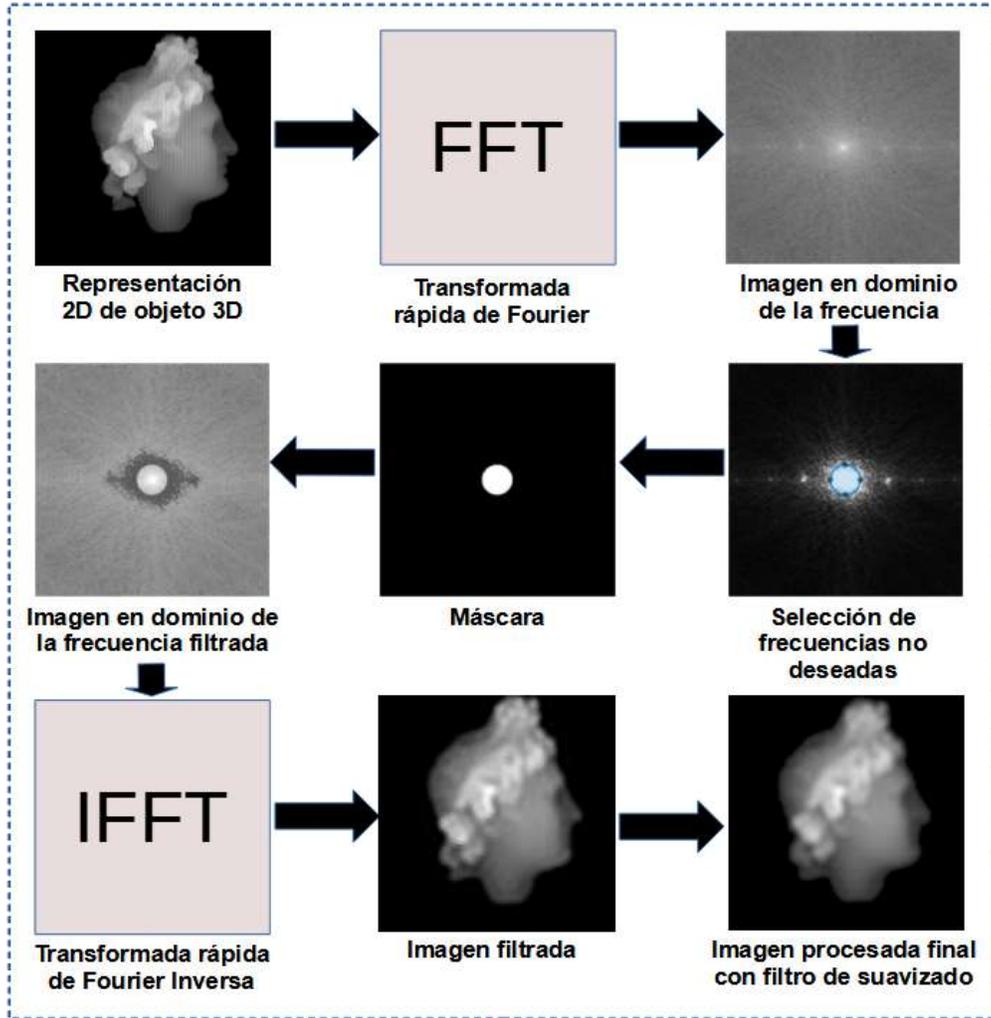


Figura 3.9: Pasos para aplicar filtro adaptable y filtro de suavizado.

lo que se inicia el proceso de filtrado en los extremos superior e inferior de la imagen convergiendo en el centro de la imagen. Debido a que la imagen en su totalidad es procesada, se crea una máscara que contiene las frecuencias originales de la región central donde se encuentra la mayor concentración de información de la imagen para su posterior recuperación cuando termina el procesamiento de la imagen [44].

El algoritmo desarrollado para atenuar el ruido cuasi/periódico se describe a continuación:

Considerando A como una imagen contaminada con ruido cuasi/periódico de tamaño $m \times n$, se determina F , mostrado en la figura 3.10 de igual tamaño mediante aplicación de transformada de Fourier usando la ecuación 3.5.

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (-1)^{x+y} A(x, y) e^{-j2\pi(\frac{ux}{M} + \frac{vy}{N})}. \quad (3.5)$$

donde $j^2 = -1$ and $(-1)^{x+y}$ denota el origen de cambio de la operación. Ya que las imágenes

contaminadas con ruido cuasi/periódico resaltan en la imagen en el dominio de la frecuencia con forma de estrella, estas regiones pueden ser fácilmente detectadas como se puede apreciar en la figura [3.10](#)

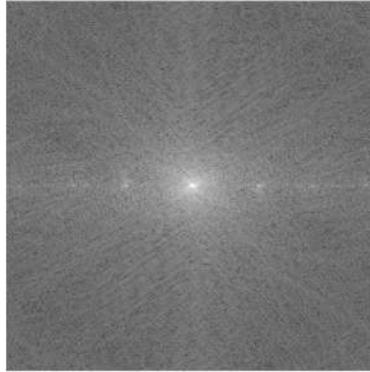


Figura 3.10: Imagen en dominio de frecuencia con ruido de cuasi/periódico visibles.

Para resaltar aún más las regiones que contienen frecuencias no deseadas, se aplica una convolución con kernel Laplaciano de 5×5 a la imagen F . El kernel utilizado se muestra en la figura [3.11](#). Utilizando la ecuación [3.6](#), la operación en la imagen F resulta en la imagen L .

-1	-1	-1	-1	-1
-1	-1	-1	-1	-1
-1	-1	24	-1	-1
-1	-1	-1	-1	-1
-1	-1	-1	-1	-1

Figura 3.11: Kernel Laplaciano de 5×5 usado para resaltar regiones con ruido cuasi/periódico.

$$L(u, v) = \sum_{ker=-2}^2 \sum_{ker=-2}^2 F(u+k, v+l) \times K(3+k, 3+l). \quad (3.6)$$

La imagen resultante con la operación de convolución con kernel Laplaciano, L , se muestra en la figura [3.12](#).

Después de aplicar convolución Laplaciana, L , es procesada para aislar las regiones con ruido, aplicando un estiramiento lineal para ajustar contraste de imagen y ajustar los valores de los píxeles a un rango definido por la ecuación [3.7](#).

$$X_{new} = \frac{X_{input} - X_{min}}{X_{max} - X_{min}} \times 255. \quad (3.7)$$

Los píxeles en L con los valores más bajos son asignados a 0 mientras que los valores más altos son asignados a 255. Los demás valores son reasignados de acuerdo con la ecuación [3.7](#). Este

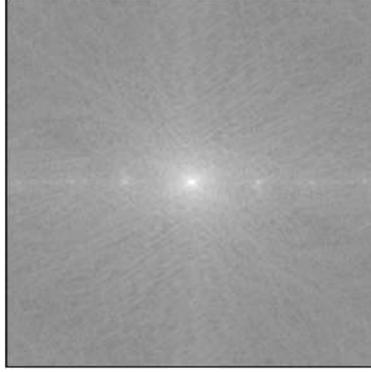


Figura 3.12: Imagen en dominio de frecuencia con ruido cuasi/periódico resaltado mediante aplicación de convolucion con kernel Laplaciano de 5×5 .

preprocesamiento final sobre las imágenes en el dominio de la frecuencia resulta en E , mostrado en la figura [3.13](#).

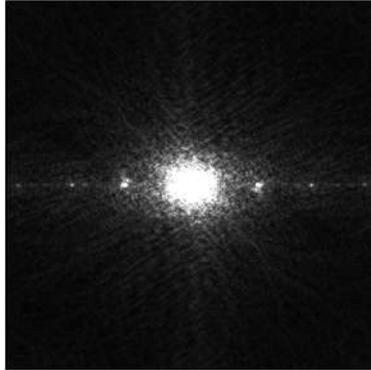


Figura 3.13: Ajuste de contraste para resaltar regiones con ruido cuasi/periódico.

Etapa de detección y filtrado de picos de frecuencia

El algoritmo desarrollado para la detección y filtrado de ruido comienza desde la parte superior e inferior de la imagen y procesa fila por fila hasta que convergen en el centro de la imagen para identificar de forma efectiva las regiones con frecuencia no deseadas. El algoritmo sigue los siguientes pasos:

Paso 1: Una imagen de tamaño similar que E es creado para obtener ventanas que permitan obtener la media y el máximo de un pixel y sus vecinos para la identificación de regiones con ruido. Imágenes de umbral iniciales $T1 = E$ y $T2 = E$ y una imagen para restauración en el dominio de la frecuencia $F_{th} = F$ son definidas. El algoritmo comienza desde la parte superior e inferior de la imagen en las posiciones $E(m = 1, n = 1)$ y $E(m = m, n = 1)$ y termina cuando converge en el centro de la imagen en la posición $E(m/2, n = n)$. Una máscara $maskF$ es creada también formando una elipse de 35 píxeles a partir del centro de la imagen. Como esta región central concentra la mayoría de información de la imagen original, es deseable que no resulte afectada.

Paso 2: Para cada pixel en la posición $E(row, col)$ se ejecutan los siguientes pasos:

Paso 2.1: Para encontrar de manera adaptativa el umbral e identificar regiones con ruido de imagen E , el algoritmo encuentra la media ($Mean$) de los vecinos del pixel que se procesa en la posición $Mean(T1(row-1 : row+1, col-1 : col+1).*(row-1 : row+1, col-1 : col+1))$ y el máximo ($Maximum$) de los valores de umbral en la posición $Maximum(T1(row-1 : row+1, col-1 : col+1).*(row-1 : row+1, col-1 : col+1))$. Un análisis de ($Mean$) y ($Maximum$), se puede concluir lo siguiente:

Caso 1: Si ($Maximum$) corresponde a un pixel con frecuencia original y su valor es menor que el valor de ($Mean$), entonces ($Maximum$) es la mejor opción para ser el valor del umbral, ya que tiene la frecuencia menor.

Caso 2: Si ($Maximum$) corresponde a una frecuencia original y su valor es mayor que ($Mean$), entonces ($Maximum$) es la mejor opción para el valor de umbral.

Caso 3: Si ($Maximum$) corresponde a un valor de frecuencia no deseado, entonces ($Mean$) es la mejor selección para el valor de umbral, ya que ($Maximum$) evidentemente es un valor muy grande de frecuencia.

Para facilitar la selección del valor de umbral, un parámetro multiplicativo α es incluido para decidir la pureza del estado del valor de la frecuencia en la posición $E(row, col)$ como $T2 = \alpha \times Minimum(m1, m2)$. α es un parámetro multiplicativo que es usado para asegurar que la superficie generada por T está siempre por encima de versión contaminada de la imagen E .

Paso 2.2: Si el valor del pixel en la posición $E(row, col)$ es más grande que el valor obtenido por el parámetro multiplicativo α , es determinado que el valor de la frecuencia en la posición es no deseada y es reemplazado por el valor de sus vecinos en la posición $F.th(row, col) = \min(\min(F.th(row-2 : row+2, col-2 : col+2)))$. De otra forma, el valor en esa posición es conservado como en la imagen original $F.th(row, col)$.

Paso 3: Una vez que todos los píxeles en la fila son procesados, el algoritmo se mueve a la siguiente fila y proceso del paso 2 comienza de nuevo.

Paso 4: Si el centro de la imagen $E(ay/2)$ es alcanzado en ambas direcciones, arriba y abajo de la imagen E , el algoritmo se termina.

Paso 5: Cuando el algoritmo se detiene, la máscara $maskF$ es sumada con la imagen en el dominio de la frecuencia $F.th$ restaurada. La imagen, mostrando las regiones con ruido de E ya restauradas, es mostrada en la figura [3.14](#).

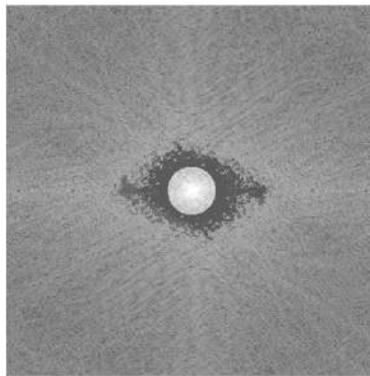


Figura 3.14: Imagen que muestra las regiones identificadas con ruido cuasi/periódico en el dominio de la frecuencia.

Cuando la imagen $F.th$ es procesada por el algoritmo de filtrado de ruido, es convertida nue-

vamente al dominio espacial mediante la transformada inversa de Fourier.

Paso 6: Finalmente, un filtro de suavizado es aplicado a la imagen convertida al dominio espacial para mejorar la atenuación de las regiones con ruido. El kernel utilizado para esta operación es mostrado en las figuras 3.15 y 3.16.

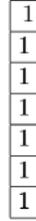


Figura 3.15: 1×7 vertical kernel [3].

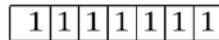


Figura 3.16: 1×7 horizontal kernel [3].

Una vez que el procesamiento de filtrado de umbral adaptable finaliza, se convierte la imagen nuevamente al dominio espacial. Después un filtro de suavizado es aplicado para mejorar la atenuación de ruido. Por último, la imagen con el ruido atenuado es mostrado en la figura 3.17a donde se hace una comparación de antes y después del filtrado, con la imagen original 3.17b.

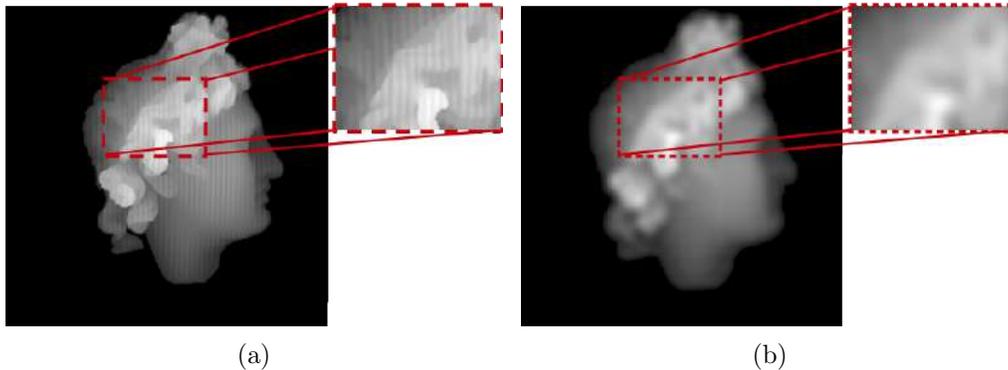


Figura 3.17: a) Imagen contaminada antes de filtrado. b) Imagen contaminada después de filtrado.

Pseudocódigo desarrollado e implementado es como sigue:

```

Read an image A
  A to grayscale
  A to double
  Set  $ax \leftarrow \text{Height}(A)$ 
  Set  $ay \leftarrow \text{Width}(A)$ 
Read mask
Set  $A \leftarrow A.*\text{mask}$ 
Set  $F \leftarrow \text{FastFourierTransform}(A)$ 

```

```

Obtain image in frequency domain F
Set f_laplace5 ← Laplacian Kernel 5x5
Set E ← (f_laplace5(m,n)-min(f_laplace5)/(max(f_laplace5)-min(f_laplace5))*255)
Set mask ← drawellipse('Center',[ax/2 ay/2], 'SemiAxes',[35 35]);
Set T1 ← E
Set T2 ← E
Set F_th ← F
Set maskF ← F.*mask
Set F_mask1 ← zeros(size(A))
Set F_mask2 ← zeros(size(A))
Set lim ← 3
Set α ← 1.3: multiplicative factor
Set β ← 0.3: umbral above the contaminated image
for row
  for col
    If E(row,col) > (alpha*T2(row,col))
      Replaces pixel on F_th ← min(F_th(row,col))
    Else
      F_th(row,col) ← F(row,col)
  T1 ← T2
Set F_filtrado ← F_th + mask
Set f ← InverseFourierTransform(f)
Set q ← q=conv2(f,a17,'same');
Fin

```

3.4. Deep CNN

El desarrollo e implementación de una red neuronal convolucional profunda nos permite utilizar las imágenes filtradas con el algoritmo propuesto para el entrenamiento de un modelo que sea capaz de atenuar el ruido cuasi/periódico en imágenes adquiridas mediante perfilometría de franjas para de esta forma automatizar el proceso de filtrado de imágenes al hacer pasar imágenes contaminadas a través del modelo entrenado, ahorrando de esta forma tiempo en el preprocesamiento de los objetos durante el proceso de reconstrucción 3D.

Para este fin se desarrolló una variante de la arquitectura de red creada por Sun(Sun, Yu, & Wang, 2018) [33]. Esta variante agrega 2 capas extras con convolución de kernel igual a 1 para mantener la arquitectura interna de la red neuronal convolucional original. Además, se ajustó el tamaño de imágenes para su entrenamiento con un tamaño de 512×512 diferente del original que entrenaba con tamaños de 256×256 .

Específicamente se agregó una capa de red que permite la entrada y convolución de imágenes con un(1) solo canal y una salida de un canal(1), como se observa en la figura 3.18, ya que la red Multiresolution-CNN creada por Sun(Sun, Yu, & Wang, 2018) [33], admite imágenes de 3 canales y proporciona una salida similar.

Las configuraciones de la red usadas en cada capa se muestran en las tablas 3.1 y 3.2.

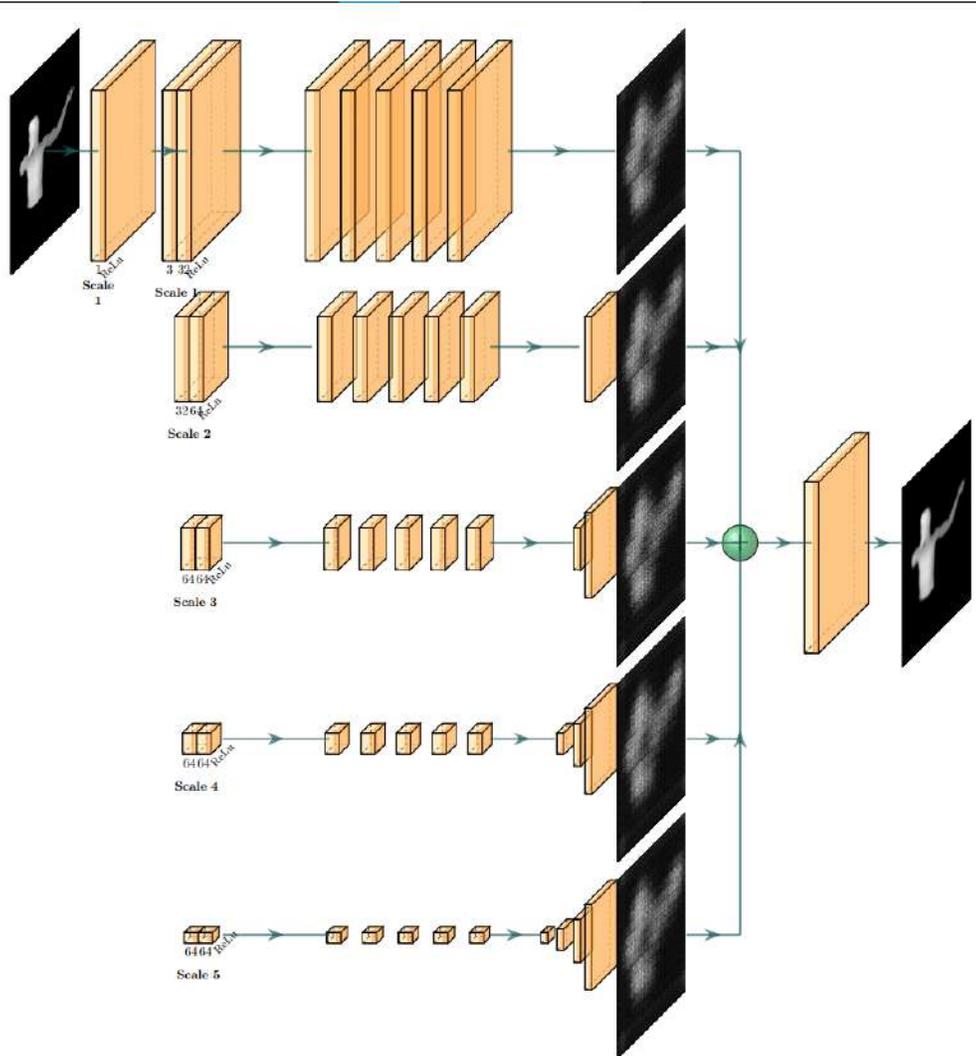


Figura 3.18: Arquitectura propuesta de red neuronal convolucional profunda.

Tabla 3.1: Capas de convolución

Scale	Type	Kernel	Stride	Channels
1	conv	1x1	1x1	1
1	conv	3x3	1x1	3
1	conv	3x3	1x1	64
1	conv	3x3	1x1	64
2	conv	3x3	2x2	128
2	conv	3x3	1x1	128
3	conv	3x3	2x2	256
3	conv	3x3	1x1	256
4	conv	3x3	2x2	512
4	conv	3x3	1x1	512
5	conv	3x3	2x2	1024
5	conv	3x3	1x1	1024

Tabla 3.2: Capas de deconvolución

Scale	Type	Kernel	Stride	Channels
1	conv	1x1	1x1	1
1	conv	3x3	1x1	3
2	deconv	4x4	2x2	128
	conv	3x3	1x1	64
	conv	3x3	1x1	64
3	deconv	4x4	2x2	256
	conv	3x3	1x1	128
	conv	3x3	1x1	128
4	deconv	4x4	2x2	512
	conv	3x3	1x1	256
	conv	3x3	1x1	256
5	deconv	4x4	2x2	1024
	conv	3x3	1x1	512
	conv	3x3	1x1	512

Resultados y Discusión

Los resultados son presentados en tres secciones diferentes, siendo la primera sección la generación de la base de datos, la segunda sección los resultados obtenidos aplicando el algoritmo propuesto y desarrollado con las imágenes obtenidas de la base de datos creada y su reconstrucción final. Finalmente, se tienen los resultados obtenidos del entrenamiento de una red neuronal convolucional con la base de datos generada y como afecta la reconstrucción 3D final de los objetos. El desarrollo del entorno de emulación del sistema de perfilometría de franjas se realiza en un ordenador personal con un procesador I7-10750H de @2.60 GHz, con 16 GB de memoria RAM y una tarjeta gráfica NVIDIA GeForce RTX 3060 con 6 GB de memoria RAM. Los experimentos y pruebas se realizan también con el equipo mencionado y Matlab 2020a.

4.1. Base de datos de imágenes

Las imágenes creadas fueron capturadas por un sistema emulado utilizando el software libre *Blender* version 2.95.5. El proyector es representado por una lámpara que proyecta franjas. La cámara tiene una longitud focal de 28 mm. Los modelos de objetos 3D son adquiridos de plataformas en línea como *TurboSquid* que también son de uso libre.

En las imágenes de la figura [4.1](#) se muestran algunas imágenes generadas para crear la base de datos. Algunos objetos muestran una superficie parecida al rostro humano, por lo que fueron seleccionados para conformar la base de datos. Otros objetos fueron seleccionados por su forma geométrica para apreciar mejor los resultados. Finalmente, se escogieron algunos con relieve complejo para observar su comportamiento y rendimiento al momento de reconstruirlos y agregar variedad a la base de datos para el entrenamiento de la red neuronal convolucional.

Las imágenes de la figura [4.1](#) muestran algunos objetos utilizados con proyección de franjas en conjuntos de 3 imágenes requeridos en el método de perfilometría de cambio de fase de 3 pasos (3-Step). En total se obtuvieron 345 escenas diferentes con proyección de franjas, sumando un total de 1035 imágenes con franjas proyectadas.

Además, también se crearon 3 mapas de referencia por escena, generando 1035 imágenes también. Adicionalmente, se creó una imagen con el objeto real 3D, 345 en total, y una imagen máscara que contiene la región de interés del objeto, 345 en total, totalizando 2760 imágenes, que componen la base de datos. Los mapas de referencia, del objeto original y la máscara de la región de interés son mostrados en la figura [3.4](#).

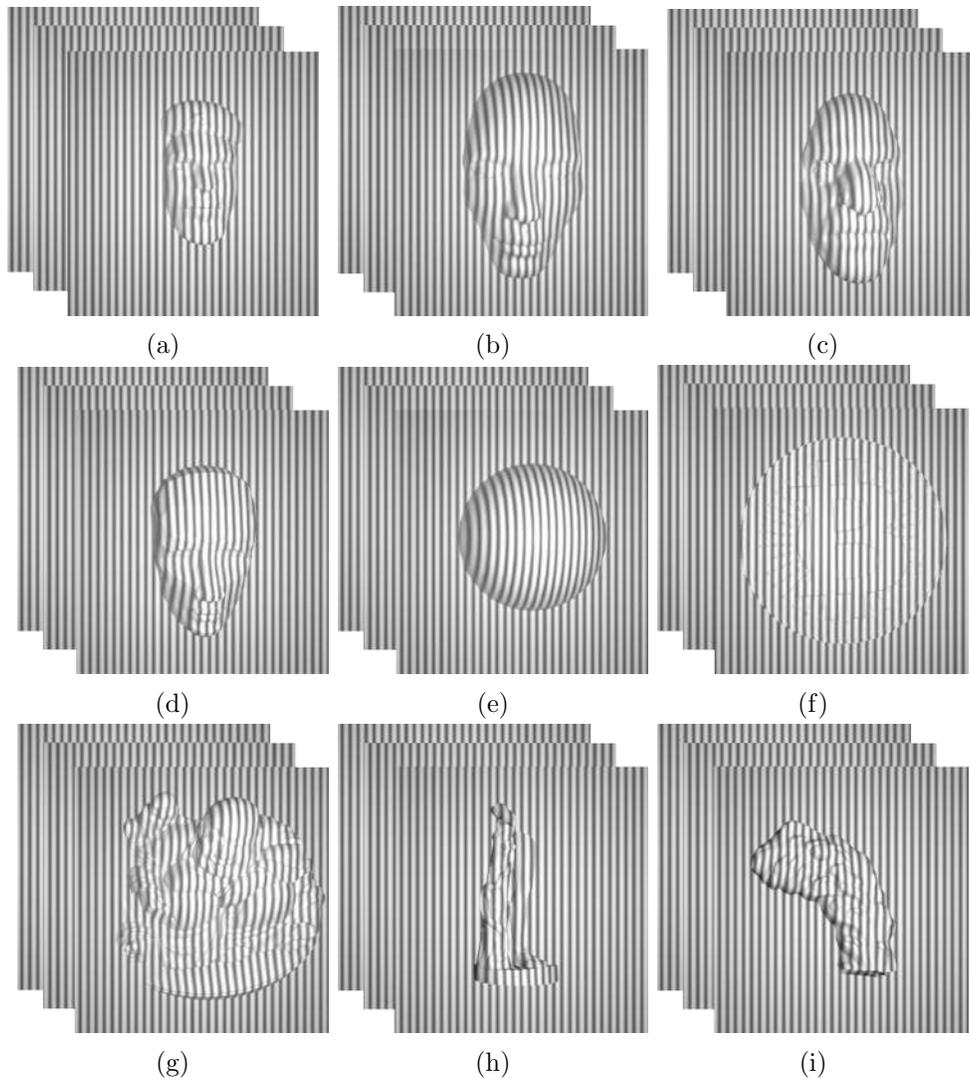


Figura 4.1: Conjunto de imágenes generados para creación de base de datos.

4.2. Reconstrucciones 3D con algoritmo desarrollado

Los resultados del algoritmo desarrollado puede observarse en las imágenes de la figura [4.2](#), que siguen la metodología utilizada implementada del algoritmo de filtro de umbral adaptativo desarrollado. Las imágenes de las figuras [4.2a](#) y [4.2b](#) muestran el objeto 3D original y la mascaró con la región de interés del objeto. En estas imágenes se puede apreciar el resultado obtenido al usar un objeto con la apariencia del rostro humano, esto para fines de aplicación de reconocimiento facial. En la imagen de la figura [4.2d](#) puede apreciarse claramente como se reduce significativamente el ruido de cuasi/periódico comparado con la imagen de la figura [4.2c](#) cuando se realiza preprocesamiento con el algoritmo desarrollado. Se aprecia claramente como se obtiene una representación 2D del objeto 3D con más ausencia de ruido cuasi/periódico.

Las imágenes de la figura [4.3](#) muestra la representación 3D de la reconstrucción del objeto mostrado en la figura [4.2](#) después de aplicar un escalamiento que ajusta las alturas mediante mini-

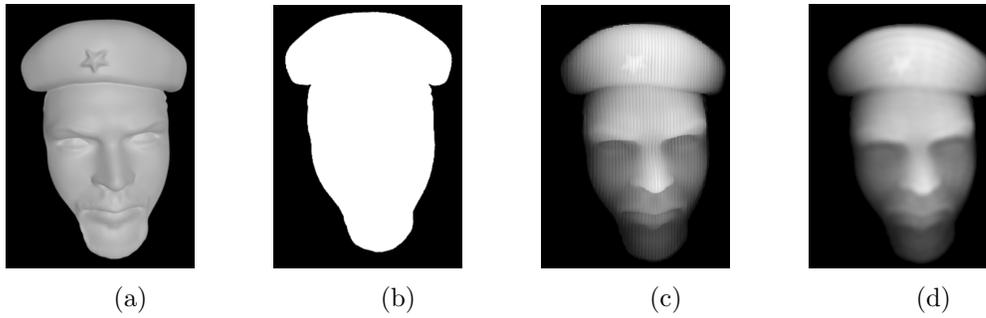


Figura 4.2: Reconstrucción de objeto 3D por etapas en visualización 2D.

mización de error cuadrático medio [45] para poder realizar la comparación. Con este escalamiento se puede realizar la comparación del objeto 3D original y el objeto 3D obtenido después de aplicar el algoritmo de filtrado propuesto. Aquí se puede apreciar mejor como el algoritmo desarrollado reduce el ruido cuasi/periódico, produciendo un objeto 3D reconstruido con una superficie más suave y, por tanto, más aproximado al objeto real.

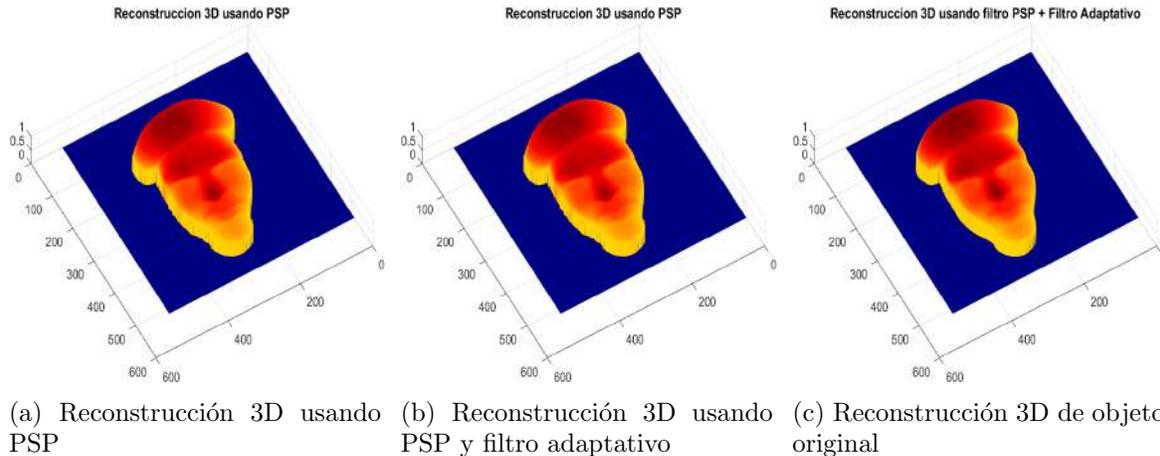


Figura 4.3: Reconstrucción de objeto 3D.

4.3. Filtro adaptativo y filtro de suavizado visto de cerca.

El resultado de aplicar el filtro desarrollado aplicado en el dominio de la frecuencia, además de un filtro de suavizado con kernel Laplaciano de 5×5 permite remover significativamente el ruido cuasi/periódico generado por el efecto de Moire producido durante la proyección de un patrón de franjas sobre un objeto 3D. Esto puede apreciarse claramente en las imágenes de la figura 4.4 además de la reconstrucción 3D del objeto mostrado en la figura 4.3. Se puede apreciar que la pérdida de información del objeto que se desea reconstruir es mínima, por lo tanto, aproximado al objeto real.

La imagen de la figura 4.5 muestra el análisis de perfil del objeto mostrado anteriormente. Se puede apreciar como el perfil del objeto 3D tratado con el filtro adaptativo y de suavizado (representado

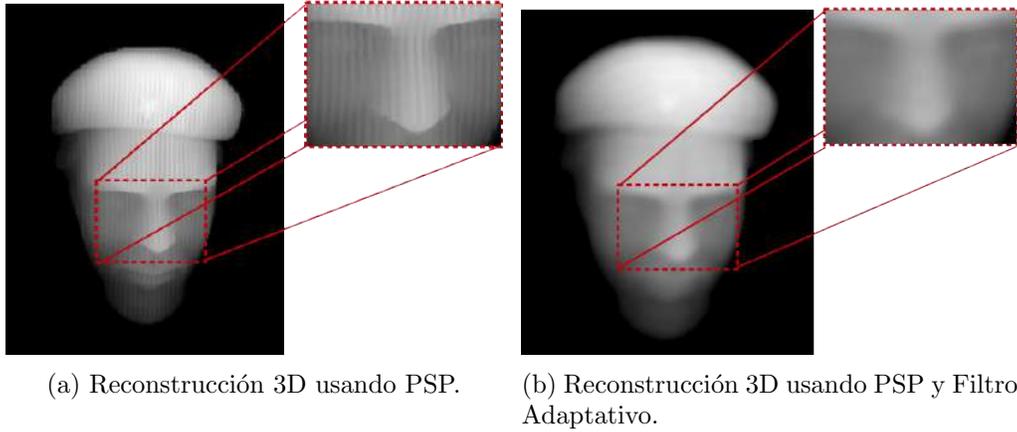


Figura 4.4: Una vista cercana al ruido cuasi/periódico tratado con el filtro adaptativo desarrollado mas filtro de suavizado.

por línea verde) muestra un perfil más suave, por lo que se aproxima mejor al objeto 3D real reconstruido. Además, se puede apreciar como el ruido de Moire presente en el perfil del objeto 3D sin aplicación del filtro desarrollado (representado por línea roja) muestra variaciones de reconstrucción bastante grandes, además, es representativo de una imagen afectada por ruido periódico o cuasi/periódico, por lo que presenta una reconstrucción con error muy grande de superficie cuando se compara con el objeto 3D original.

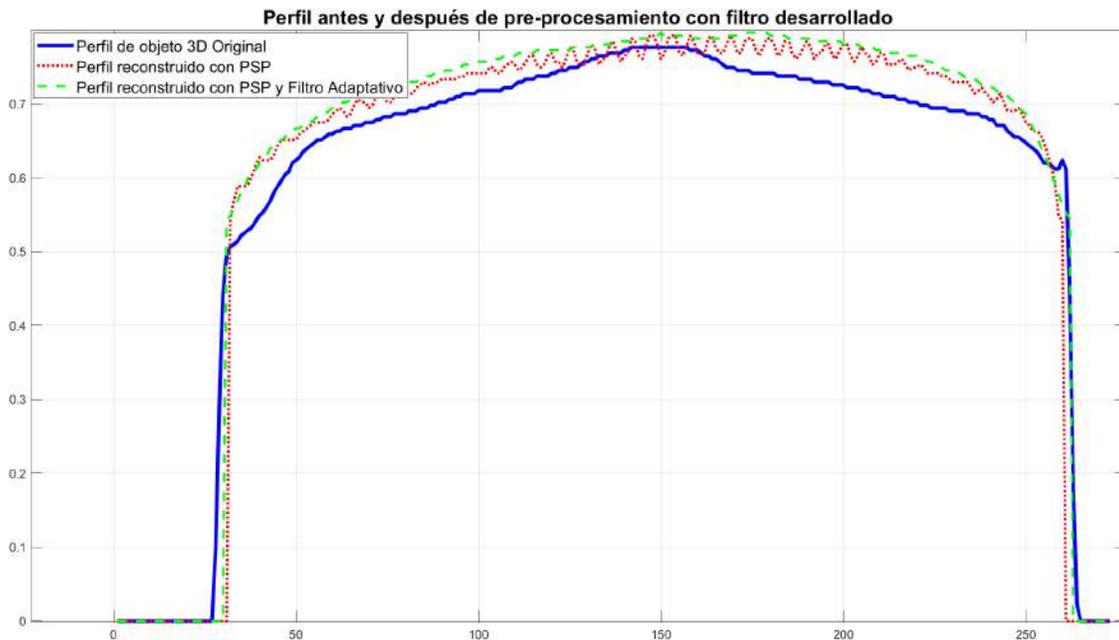


Figura 4.5: Análisis de perfil de objeto 3D reconstruido antes y después de aplicar filtro adaptativo desarrollado y suavizado desarrollado.

4.4. Entrenamiento de Red Neuronal Convolutiva Profunda (Deep CNN)

Para realizar el entrenamiento de la red neuronal propuesta, se utiliza la base de datos generada con software *Blender*, en el que se pre procesaron las imágenes con ruido cuasi/periódico una vez que se le aplicó la extracción y desenvolvemento de fase usando el algoritmo desarrollado, esto para obtener las imágenes objetivo(target) de cada imagen afectada por ruido cuasi/periódico. Este entrenamiento se realizó en un ordenador personal con un procesador I7-10750H de @2.60 GHz, con 16 GB de memoria RAM y una tarjeta gráfica NVIDIA GeForce RTX 3060 Laptop GPU con 6 GB de memoria RAM. Se usó también el software Python 3.7.11, librería Pytorch 1.9.0, y entorno de programación PyCharm Community Edition 2021.1.1. Además, también se usó una tarjeta gráfica NVIDIA GeForce GTX 1070 para comparación de rendimiento de entrenamiento.

Las 345 imágenes se dividieron en proporción de 70 % para entrenamiento, 10 % para validación y 20 % para pruebas siguiendo la metodología propuesta por Sun(Sun, Yu, & Wang, 2018)[33]. Algunas imágenes de la base de datos pueden observarse en la figura 4.6 tanto la imagen con ruido cuasi/periódico como su correspondiente imagen objetivo pre-procesada con el algoritmo desarrollado para atenuar el ruido cuasi/periódico.

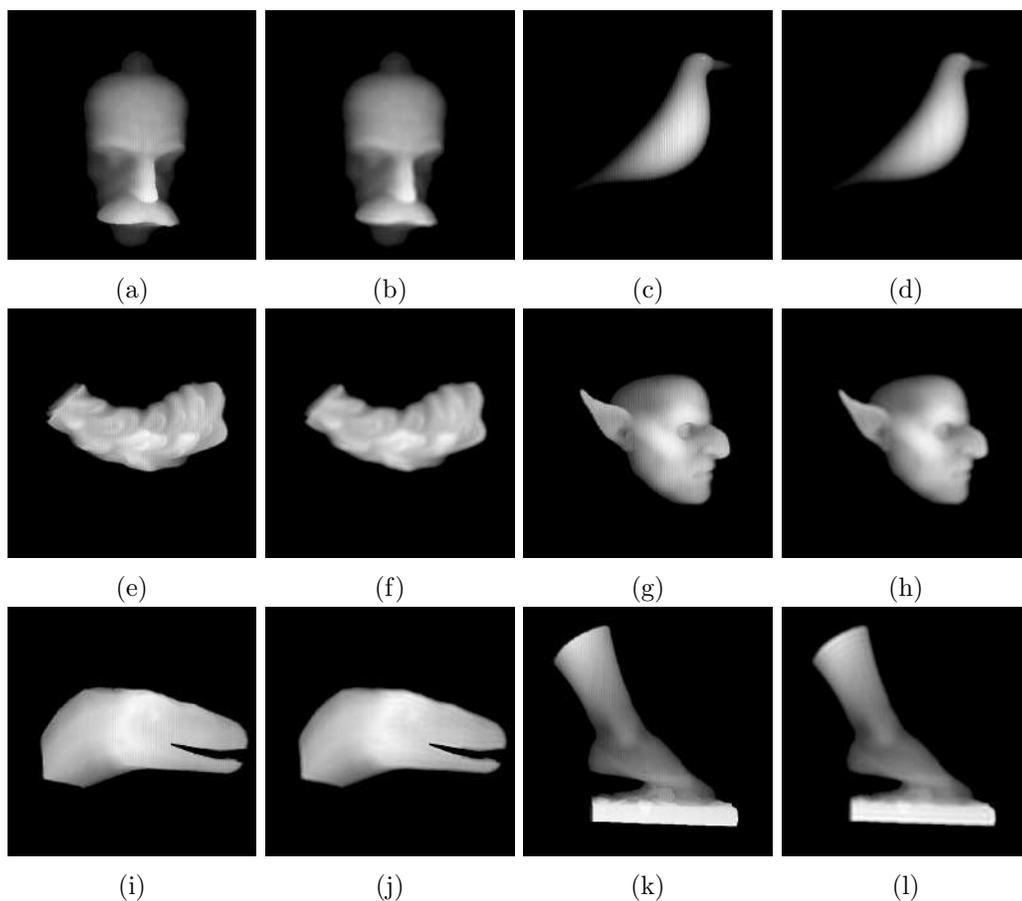
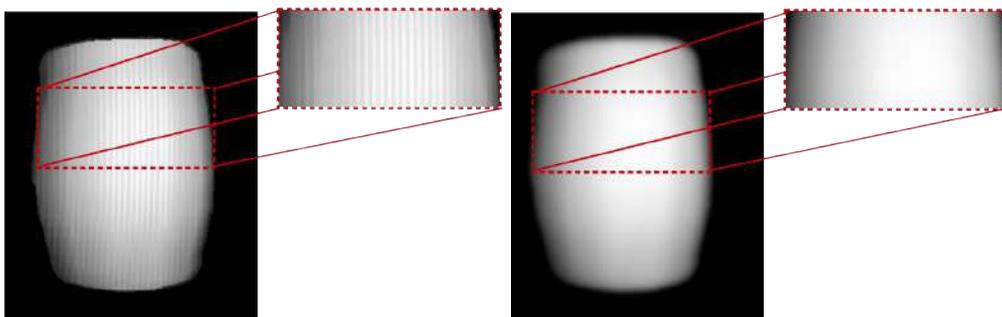


Figura 4.6: Imágenes de base de datos generada para entrenamiento de Red Neuronal Convolutiva Profunda (CNN). Imágenes a), e), i), c), g) y k) con ruido, e imágenes b), f), j), d), h) y l) filtradas.

Se puede observar la amplia variedad de imágenes utilizadas para el entrenamiento, esto con el fin de tener una variedad al realizar el entrenamiento y hacer una generalización mayor al filtrar tanto objetos 3D simples como objetos 3D complejos.

El entrenamiento de la red propuesta fue realizado en 00:44:48 horas, alcanzando una pérdida por entrenamiento (Train Loss) de $6.4e-5$ y una pérdida por validación (**Val Loss**) de 0.000127, como se muestra en la gráfica de la figura 4.10d.

Como resultado de aplicar la red neuronal entrenada con imágenes con representación 2D de objetos que contienen ruido cuasi/periódico, se muestra una atenuación del ruido cuasi/periódico en imágenes adquiridas mediante perfilometría de franjas. Esto puede apreciarse en las imágenes de la figura 4.7 donde se muestra un objeto representado en 2D del conjunto de pruebas utilizado para probar la red desarrollada e implementada. Se puede apreciar en la imagen aumentada 4.7a la presencia de ruido cuasi/periódico en la imagen del objeto 3D, mientras que en la imagen de la figura 4.7b se muestra la ausencia del ruido de cuasi/periódico.

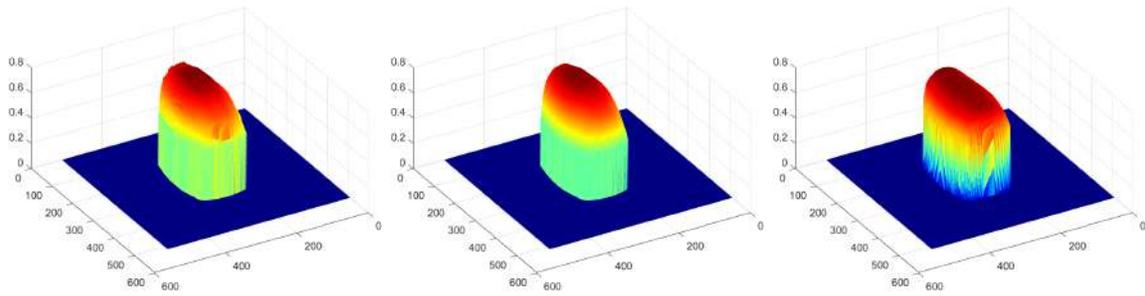


(a) Antes de procesamiento con CNN propuesto. (b) Después de procesamiento con CNN propuesto.

Figura 4.7: Vista cercana del ruido de Moire procesado con la red neuronal convolucional desarrollada (Multiresolution CNN Modified).

La imagen de la figura 4.8 muestra la reconstrucción 3D del objeto utilizado en la figura 4.7, en el que se le aplica un escalamiento de alturas para su comparación con el objeto original [45]. Se puede apreciar como el preprocesamiento realizado con la red neuronal convolucional (Multiresolution-CNN Modified) atenúa completamente el ruido cuasi/periódico presente en la imagen, produciendo un objeto 3D reconstruido más suave en su superficie y aproximado al objeto real.

Un análisis posterior mostrado en la figura 4.9 muestra el perfil del objeto 3D reconstruido a partir de la representación 2D procesada con la red Multiresolution-CNN Modified mostrado anteriormente. Se aprecia como el perfil del objeto 3D obtenido con la red entrenada produce un perfil más suave comparado con el objeto con ruido cuasi/periódico original, por lo que su reconstrucción es más suave, y, por tanto, más cercano al objeto original.



(a) Reconstrucción 3D usando PSP. (b) Reconstrucción 3D usando PSP y Multiresolution-CNN Modified. (c) Reconstrucción 3D de Objeto Original.

Figura 4.8: Reconstrucción de objeto 3D.

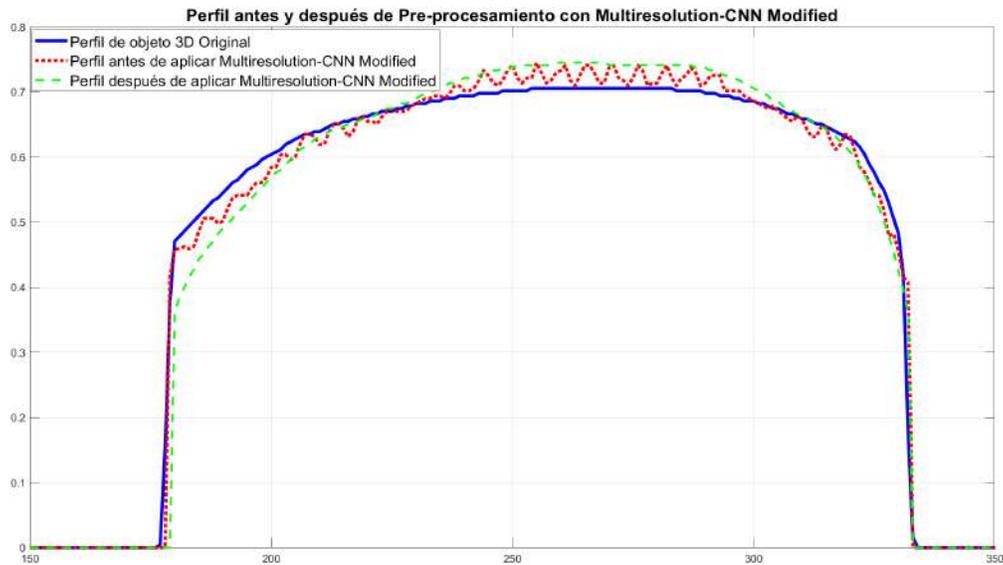


Figura 4.9: Análisis de perfil de objeto 3D reconstruido antes y después de pre-procesamiento con Multiresolution-CNN Modified.

4.5. Comparación con otras arquitecturas

La metodología propuesta presentada en este trabajo se basa en una versión modificada de la red neuronal convolucional propuesta por Sun (Sun, Yu, & Wang, 2018) [33]. Se realiza una comparación con otras arquitecturas, incluyendo la misma arquitectura original en la que se basó el modelo de red propuesto. Se aprecia durante las comparaciones una mejor calidad visual obtenida con la red propuesta (ver fig. 4.12). Las arquitecturas de red utilizadas para comparación son el modelo UNet propuesta por Ronneberger (Ronneberger, Fischer, & Brox, 2015) [46], el modelo Multiresolution-CNN (Sun, Yu, & Wang, 2018) [33], y el modelo FCN32s propuesto por Long (Long, Shelhamer, & Darrel, 2015) [47]. Para hacer las comparaciones entre estos modelos seleccionados se compararon 2 objetos, uno usando un objeto que es similar a un rostro humano y otro usando un objeto más complejo. Los parámetros utilizados para comparación se muestran en la tabla 4.1. Se

utilizaron los mismos parámetros para igualar las condiciones que mejor se obtuvieron con la red Multiresolution-CNN Modified propuesta.

Tabla 4.1: Parámetros usados durante el entrenamiento de redes para comparación

Parámetro	UNet	FCN32s	Multires-CNN	Multires-CNN Modified
Tamaño de lote(batch-size)	4	4	4	4
Pesos iniciales (weights initials)	Aleatorio Gaussiano (Mean=0.0, std=0.01)			
Bias	0.0	0.0	0.0	0.0
Tasa de aprendizaje(rate learning)	0.0001	0.0001	0.0001	0.0001
Optimizador	Adam	Adam	Adam	Adam
Función de perdida	MSE	MSE	MSE	MSE
Plan de entrenamiento (train, val, test)	70 %, 10 %, 20 %	70 %, 10 %, 20 %	70 %, 10 %, 20 %	70 %, 10 %, 20 %
Tamaño de imágenes (Width, Height)	512×512 píxeles	512×512 píxeles	512×512 píxeles	512 × 512 píxeles
Cantidad de imágenes (Train)	276	276	276	276
Cantidad de imágenes (Val)	27	27	27	27
Cantidad de imágenes (Test)	69	69	69	69

Las gráficas mostradas en la figura [4.10](#) visualizan la evolución de la pérdida por entrenamiento y validación de cada modelo CNN, tanto el propuesto como los seleccionados para comparación, observándose una evolución más uniforme el correspondiente al modelo propuesto, mostrado en la gráfica [4.10d](#).

Se aprecia además un adecuado entrenamiento de cada modelo, incluyendo los destinados para tareas de segmentación, lo que demuestra su potencial para tareas de restauración de imágenes con las correspondientes adecuaciones al modelo original, incluyendo parámetros.

Se puede observar también como convergen hacia un valor de pérdida bajo en todos los modelos, que, de acuerdo con la literatura, indica un buen aprendizaje de los modelos, además de otros factores.

Los valores de pérdida por entrenamiento y validación, además del tiempo de entrenamiento de cada modelo, se muestran en la tabla [4.2](#).

Las gráficas de la figura [4.11](#) muestran la evolución de la pérdida por entrenamiento y por validación de los modelos seleccionados en comparación con el modelo propuesto representado por línea roja.

La figura [4.12](#) muestra la representación 2D del objeto 3D que representa un rostro humano, y es la primera prueba que se realizó para comparar el rendimiento de la arquitectura de red propuesta con otros modelos existentes. Se puede apreciar la mayor aproximación conseguida con el modelo propuesto de red neuronal convolucional. Además, se aprecia la pérdida de información de algunos

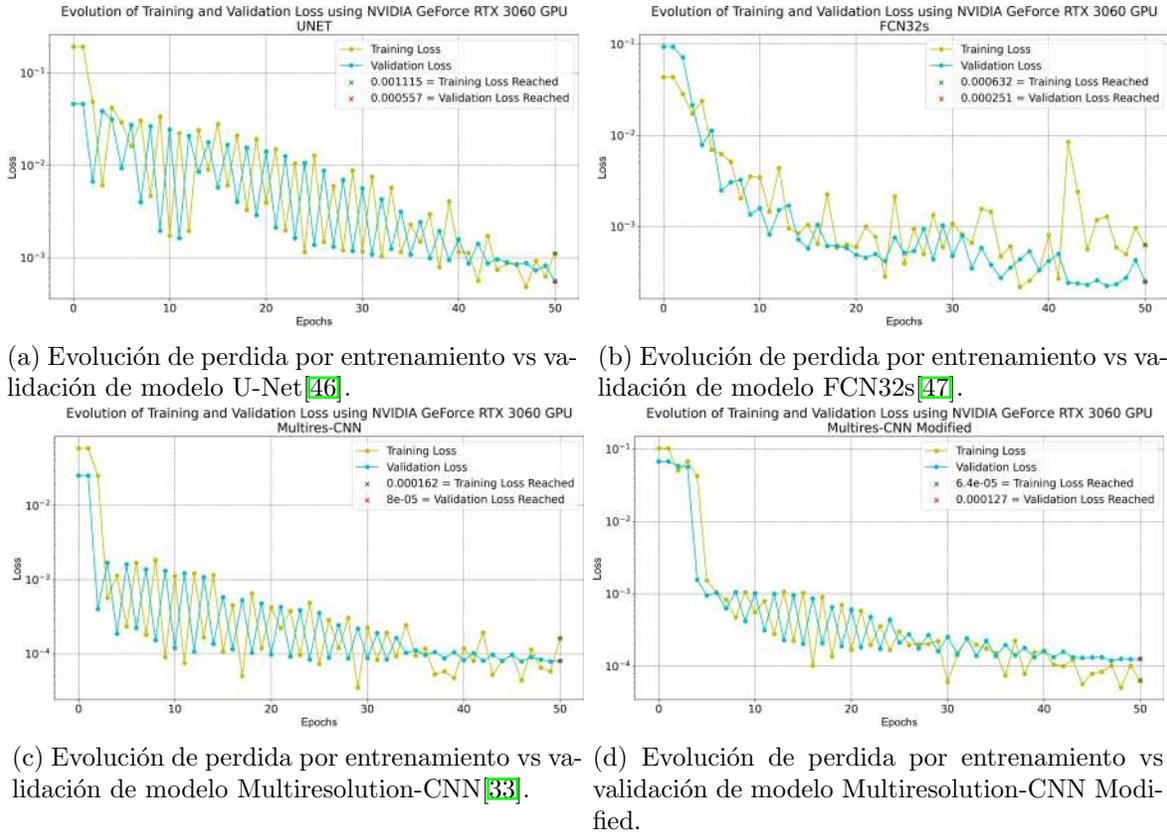


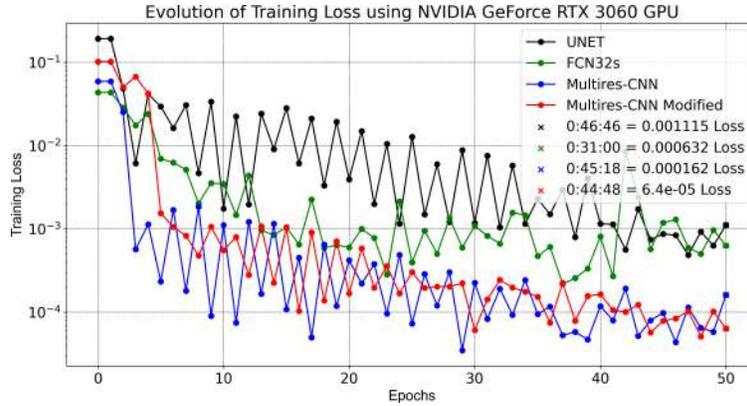
Figura 4.10: Evolución de pérdida de entrenamiento y validación de los modelos entrenados seleccionados para comparación con el modelo propuesto.

Tabla 4.2: Resultados del entrenamiento de redes para comparación

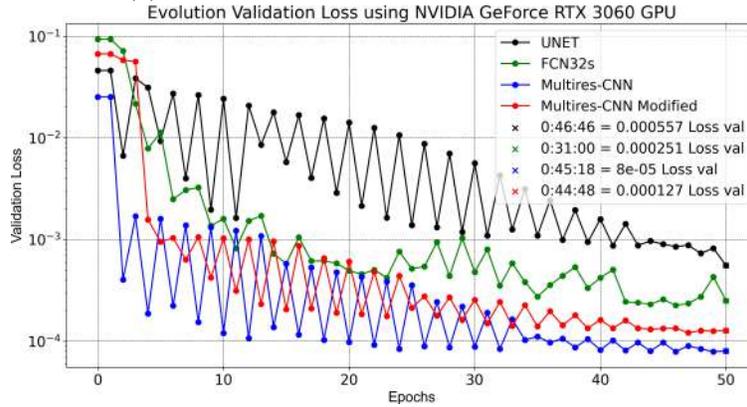
Resultados	UNet	FCN32s	Multires-CNN	Multires-CNN Modified
Perdida por entrenamiento(Loss train)	0.001115	0.000544	0.000162	6.4e-05
Perdida por validación (Loss val)	0.000557	0.000307	8e-05	0.000127
Tiempo de entrenamiento (HH:MM:SS)	00:46:46	00:30:58	00:45:18	00:44:48

modelos, esto porque las configuraciones originales involucran un corte en la imagen con una capa de *Pooling* para su procesamiento, por lo que se ve afectada en su dimensión original cada imagen.

Todos los entrenamientos se llevaron a cabo con imágenes de 512×512 píxeles, sin embargo, se realizaron ajustes para que las CNN aceptaran el tamaño de imagen creado. Así, la arquitectura de red Multiresolution-CNN [33] recibe imágenes de 256×256 píxeles por lo que se realiza un corte a partir del centro de la imagen para su entrenamiento, mientras que la arquitectura de red neuronal



(a) Evolución de perdida por entrenamiento.



(b) Evolución de perdida por validación.

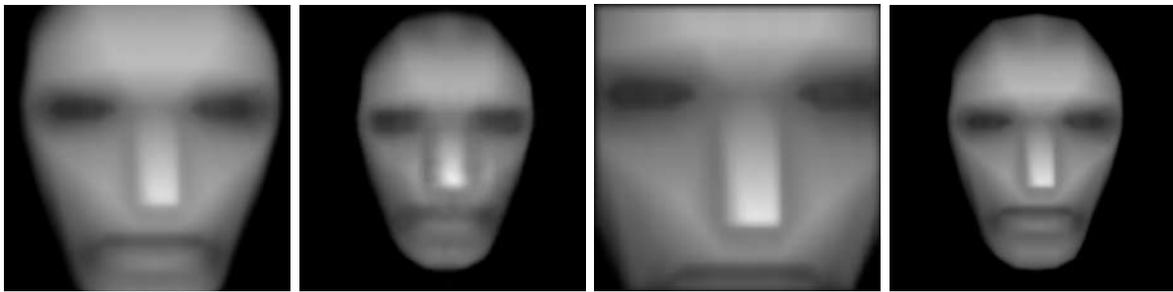
Figura 4.11: Evolución de perdida de los modelos entrenados seleccionados para comparación con el modelo propuesto.

convolucional UNET [46], recibe imágenes de tamaño 572×572 píxeles por lo que en este caso se redimensiona la imagen recibida a dichas dimensiones, todo usando los métodos proporcionados por la librería *Pytorch*. Las arquitecturas FCN32s [47] y Multiresolution-CNN Modified (Propuesto) se entrenaron con imágenes de tamaño 512×512 píxeles, ya que están adaptadas para recibir de este tamaño.

La figura 4.13 muestra la reconstrucción 3D realizada con el objeto seleccionado para comparación (la figura 4.12), obtenidos con los diferentes modelos. En este caso no se realizó ajuste de alturas debido a que las dimensiones del objeto 3D de cada CNN resultaba afectado, además solo se realiza una comparación de los objetos 3D reconstruidos.

Se tomó un objeto simétrico para hacer un análisis completo del objeto y realizar una comparación con el objeto 3D original. Las imágenes de la figura 4.14 muestran el objeto 3D en su representación 2D inferida de cada modelo que se utilizó, tanto el que se desarrolló como los que se utilizaron para comparación. Los objetos a diferencia del objeto utilizado en la figura 4.13 pudo ser inferida de manera completa debido al tamaño original del objeto 3D, por lo que su visualización es completa y se usa para obtener las métricas más completas y confiables.

Se efectuaron varias mediciones, incluyendo un análisis de perfil del objeto con el fin de comparar



(a) Objeto 3D obtenido con UNET. (b) Objeto 3D obtenido con FCN32s. (c) Objeto 3D obtenido con Multiresolution-CNN. (d) Objeto 3D obtenido con Multiresolution-CNN Modified.

Figura 4.12: Representación 2D de objetos 3D obtenidos con diferentes arquitecturas de CNN

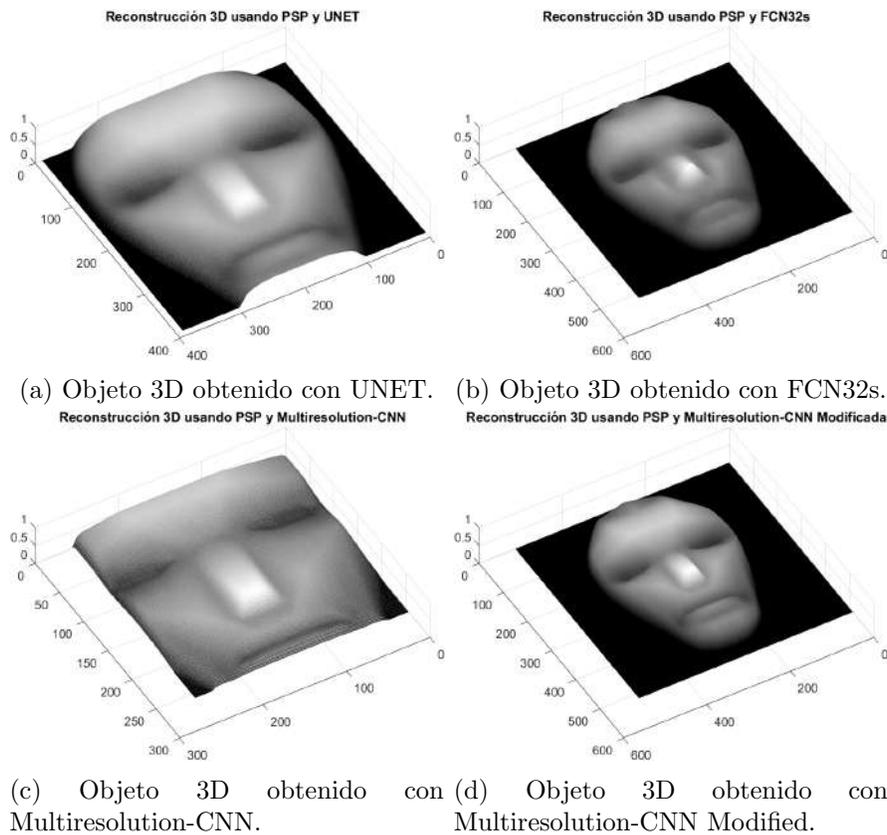


Figura 4.13: Reconstrucción de objeto 3D obtenido con diferentes arquitecturas de CNN y objeto original reconstruido con PSP.

el rendimiento de la metodología aplicada. La figura 4.15 muestra el análisis de perfil después de aplicar un escalamiento que ajusta las alturas mediante minimización de error cuadrático medio [45] para poder realizar la comparación.

Con este escalamiento se puede realizar la comparación del objeto 3D original y los objetos 3D obtenidos con entrenamiento de las redes neuronales convolucionales seleccionadas. En la figura

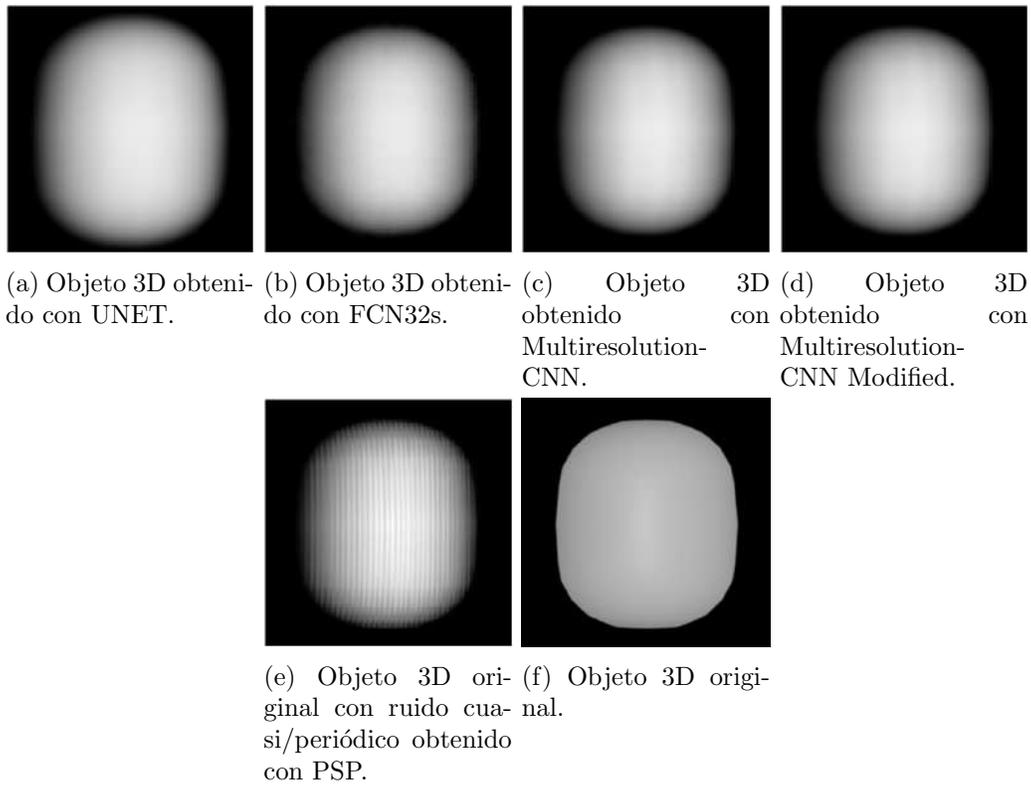


Figura 4.14: Representación 2D de objeto 3D obtenido con diferentes arquitecturas de CNN y objeto original reconstruido con PSP.

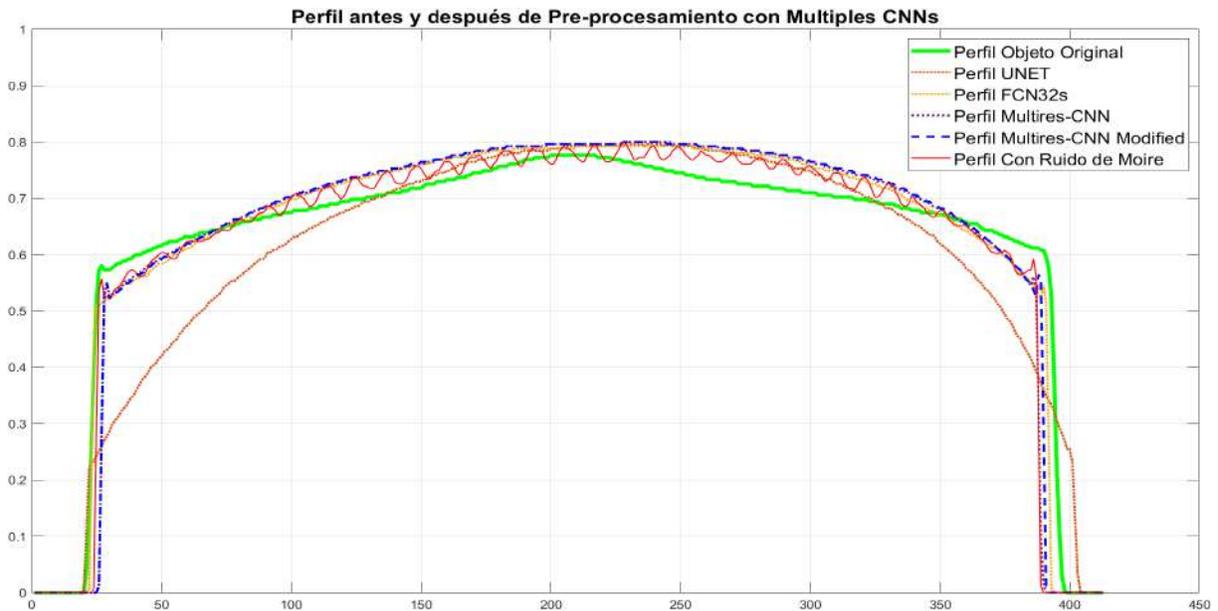


Figura 4.15: Análisis de perfil antes y después de procesamiento con redes entrenadas seleccionadas.

4.16 se puede apreciar que las estimaciones de alturas y los ejes son los mismos.

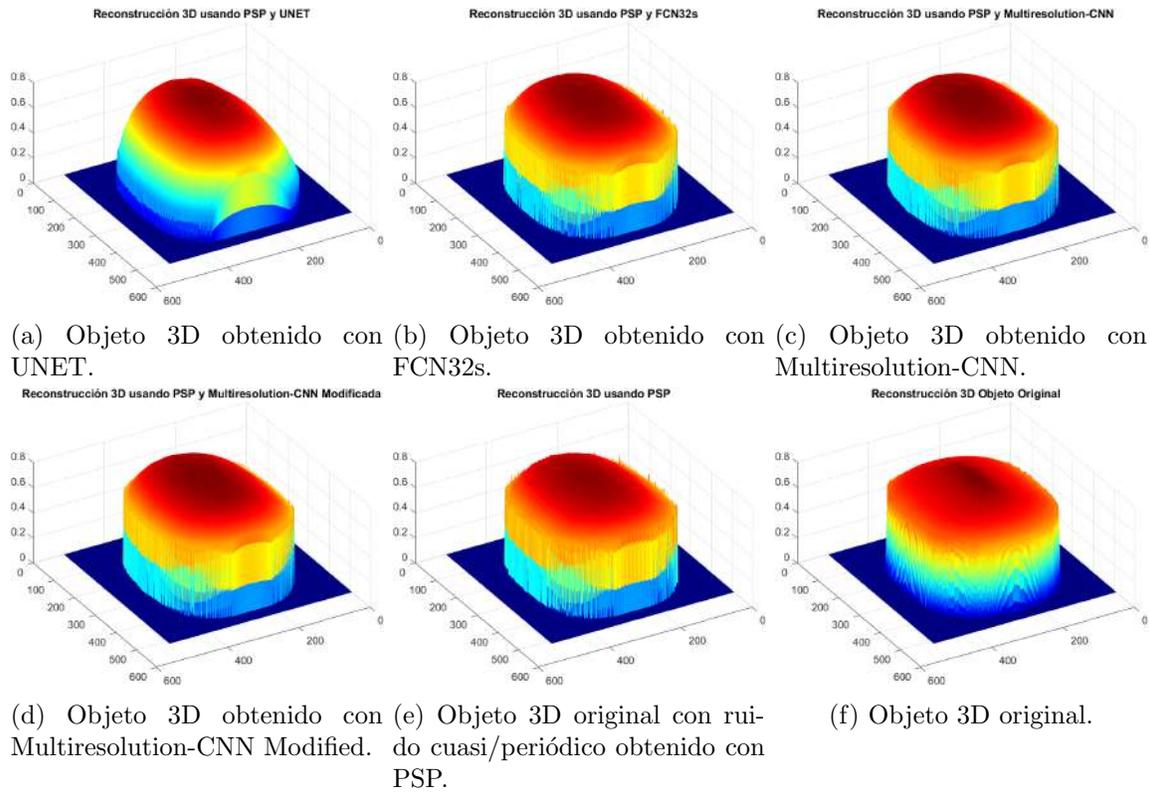


Figura 4.16: Reconstrucciones de objeto 3D obtenido con diferentes arquitecturas de CNN, objeto 3D original con ruido y objeto 3D original.

Los resultados mostrados en la tabla 4.3 corresponden a las mediciones cuantitativas que se realizaron tomando las representaciones 2D del objeto 3D mostrado en la figura 4.16 y se puede apreciar el rendimiento de la metodología propuesta sobre los demás modelos que se tomaron para comparación excepto para el caso de la red FCN32s, que si bien obtuvo más altas puntuaciones, de forma cualitativa el objeto 3D obtenido, presenta irregularidades en su forma por lo que no se acerca al objeto original presentando un mayor error de reconstrucción 3D, además se pierde información y detalles. Esto se puede apreciar mejor en la representación 2D de los objetos mostrados en la figura 4.13b.

Cabe resaltar que para obtener las métricas se cortó la imagen a partir del centro de la imagen para obtener una imagen de dimensiones finales de 256×256 para tener una comparación correcta y que se ajustara a las dimensiones de las 3 CNN's seleccionadas para comparación, la CNN propuesta y el objeto 3D original. El tamaño original del objeto no se modificó dado que solo se realizó el corte para igualar dimensiones y eliminar espacios no útiles de la reconstrucción 3D de los objetos y realizar las mediciones más precisas.

Tabla 4.3: Métricas obtenidas a partir de objetos 3D resultantes de entrenamiento de diferentes arquitecturas CNNs.

Modelo CNN	PSNR	IMMSE	SSIM	MSE(Perfil)
Multiresolution-CNN Modified	23.8290	0.0041	0.9510	0.0054
UNET	20.8971	0.0081	0.9084	0.0078
FCN32s	27.1734	0.0019	0.9659	0.0021
Multiresolution-CNN	23.7022	0.0043	0.9499	0.0065

4.6. Resultados de entrenamiento usando GPU GeForce GTX 1070.

Los parámetros utilizados para entrenamiento con arquitecturas propuesta y seleccionadas para comparación son los mismos que se presentaron en la tabla [4.4](#).

Tabla 4.4: Parámetros usados durante el entrenamiento de redes para comparación

Parámetro	UNet	FCN32s	Multires-CNN	Multires-CNN Modified
Tamaño de lote(batch-size)	4	4	4	4
Pesos iniciales (weights initials)	Aleatorio Gaussiano (Mean=0.0, std=0.01)			
Bias	0.0	0.0	0.0	0.0
Tasa de aprendizaje(rate learning)	0.0001	0.0001	0.0001	0.0001
Optimizador	Adam	Adam	Adam	Adam
Función de pérdida	MSE	MSE	MSE	MSE
Plan de entrenamiento (train, val, test)	70 %, 10 %, 20 %	70 %, 10 %, 20 %	70 %, 10 %, 20 %	70 %, 10 %, 20 %
Tamaño de imágenes (Width, Height)	512×512 píxeles	512×512 píxeles	512×512 píxeles	512 × 512 píxeles
Cantidad de imágenes (Train)	276	276	276	276
Cantidad de imágenes (Val)	27	27	27	27
Cantidad de imágenes (Test)	69	69	69	69

La evolución de pérdida por entrenamiento y validación de cada modelo CNN que se entrenó son mostrados en las gráficas de la figura [4.17](#), en los que se puede apreciar que el entrenamiento

de los modelos es uniforme, sin embargo, teniendo diferencias principalmente en la duración de los entrenamientos mientras que las mostradas en la figura 4.18 muestran la evolución de las pérdidas por entrenamiento y validación de los modelos entrenados en conjunto.

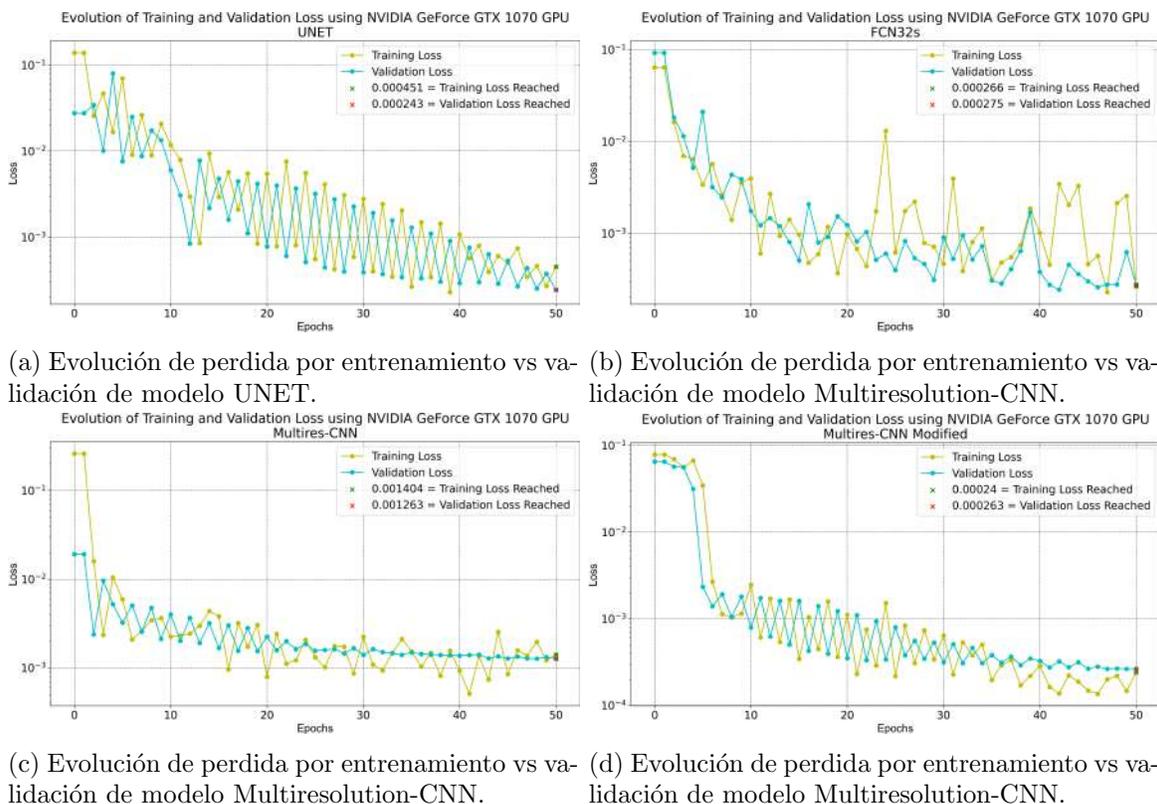


Figura 4.17: Evolución de pérdida de entrenamiento y validación de los modelos CNN entrenados para comparación con modelo propuesto.

Los valores de pérdida por entrenamiento y validación, además del tiempo de entrenamiento de cada modelo usado, además del propuesto, son mostrados en la tabla 4.5

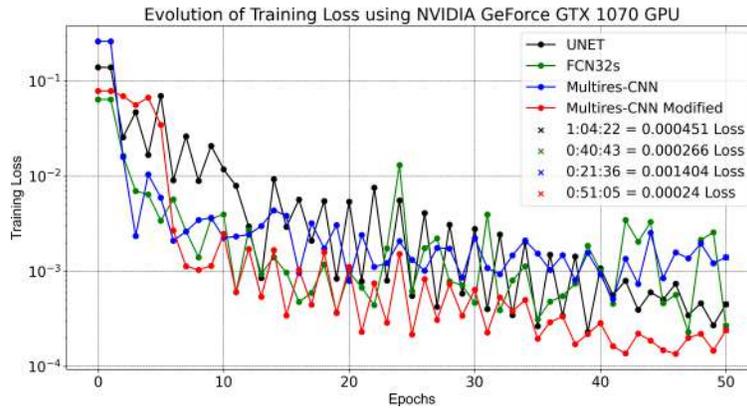
Las inferencias realizadas usando los modelos entrenados con la tarjeta gráfica usada para esta prueba se muestran en las imágenes de la figura 4.19, en las cuales se aprecia que aunque se consigue reducir el ruido cuasi/periódico de las representaciones 2D de objetos, muestran objetos con pérdidas de información de detalles, sin embargo, se aprecia buenas inferencias con algunos modelos.

La figura 4.20 muestra las reconstrucciones 3D de los objetos inferidos por cada modelo entrenado. Al igual que el entrenamiento realizado con la tarjeta gráfica RTX 3060, las inferencias generadas por los modelos entrenados producen objetos 3D más suaves y aproximados al reconstruir el objeto mostrado que en este caso tiene apariencia de un rostro humano. Aunque algunas reconstrucciones muestran el objeto parcial, se observa claramente como la reconstrucción realizada muestra una superficie más suave, esto debido a que el ruido cuasi/periódico que afectaba al objeto se ha atenuado considerablemente.

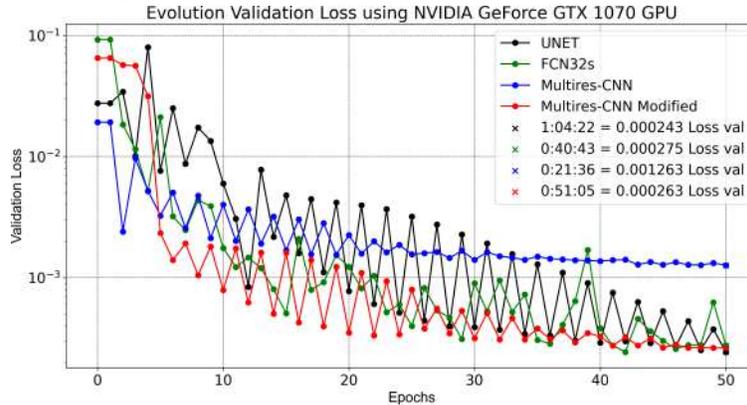
Al igual que ocurrió con los análisis de resultados usando la tarjeta gráfica RTX 3060 para el entrenamiento y análisis anterior, aquí se hizo uso de un objeto simétrico y completo inferido

Tabla 4.5: Resultados del entrenamiento de redes para comparación

Resultados	UNet	FCN32s	Multires-CNN	Multires-CNN Modified
Perdida por entrenamiento(Loss train)	0.000451	0.000266	0.001404	0.00024
Perdida por validación (Loss val)	0.000243	0.000275	0.001263	0.000263
Tiempo de entrenamiento (HH:MM:SS)	1:04:22	00:40:43	00:21:36	00:51:05



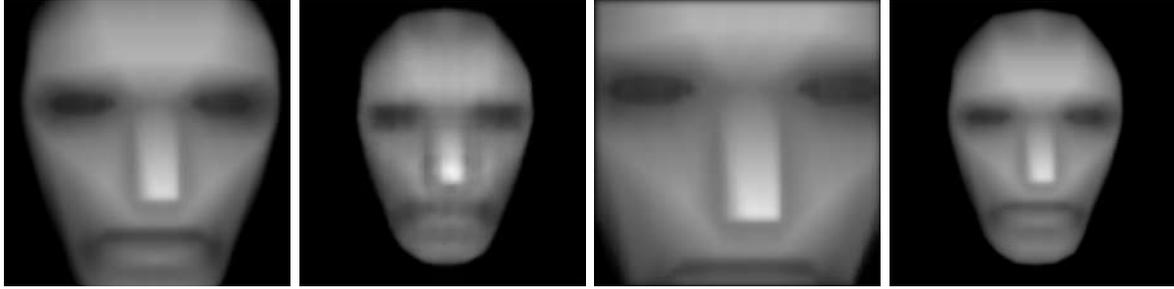
(a) Evolución de perdida por entrenamiento de modelos entrenados y propuesto.



(b) Evolución de perdida por validación de modelos entrenados y propuesto.

Figura 4.18: Evolución de perdida de entrenamiento y validación de los modelos CNN entrenados para comparación con modelo propuesto.

por cada modelo entrenado con el fin de efectuar mediciones y obtener las métricas cuantitativas utilizando el objeto original que fue utilizado en el conjunto de prueba de los modelos. El objeto original usado y las inferencias son mostrados en la figura [4.21](#).



(a) Objeto 3D obtenido con UNET usando GPU GTX 1070. (b) Objeto 3D obtenido con FCN32s usando GPU GTX 1070. (c) Objeto 3D obtenido con Multiresolution-CNN usando GPU GTX 1070. (d) Objeto 3D obtenido con Multiresolution-CNN Modified usando GPU GTX 1070.

Figura 4.19: Representación 2D de objetos 3D obtenidos con diferentes arquitecturas de CNN y representación 2D original con ruido.

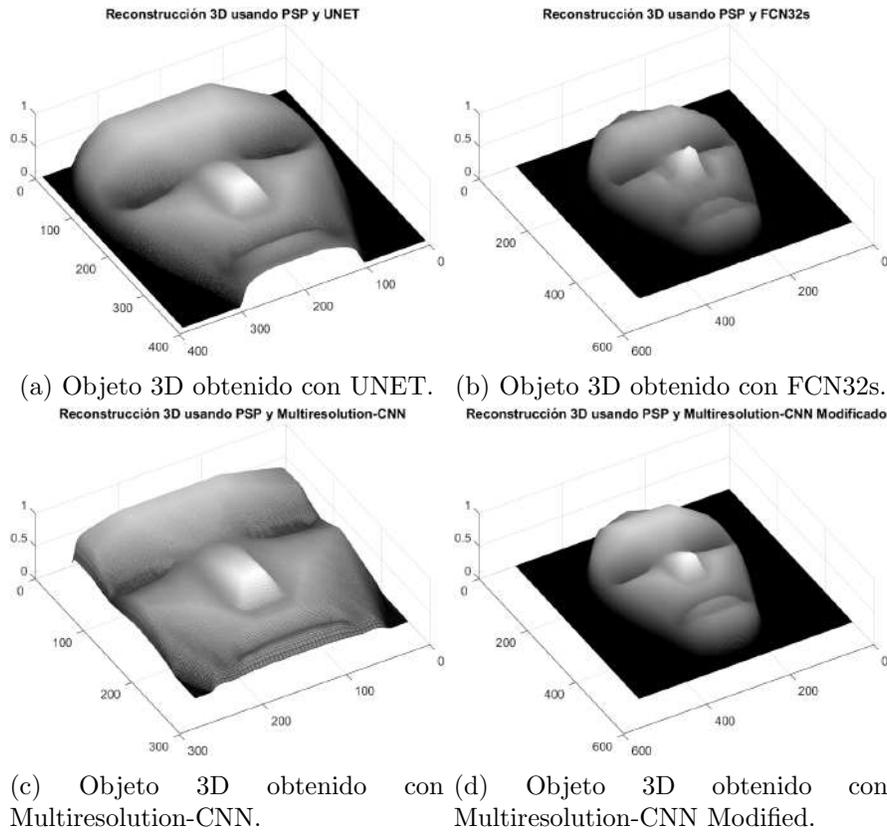


Figura 4.20: Reconstrucción de objeto 3D obtenido con diferentes arquitecturas de CNN

El análisis del perfil de cada objeto inferido por cada modelo entrenado muestra una reconstrucción suave y cercana al objeto original en el caso del modelo de arquitectura propuesto, como puede observarse en la gráfica de la figura [4.22](#).

Asimismo, los objetos 3D reconstruidos a partir de dicha inferencia producida por cada modelo

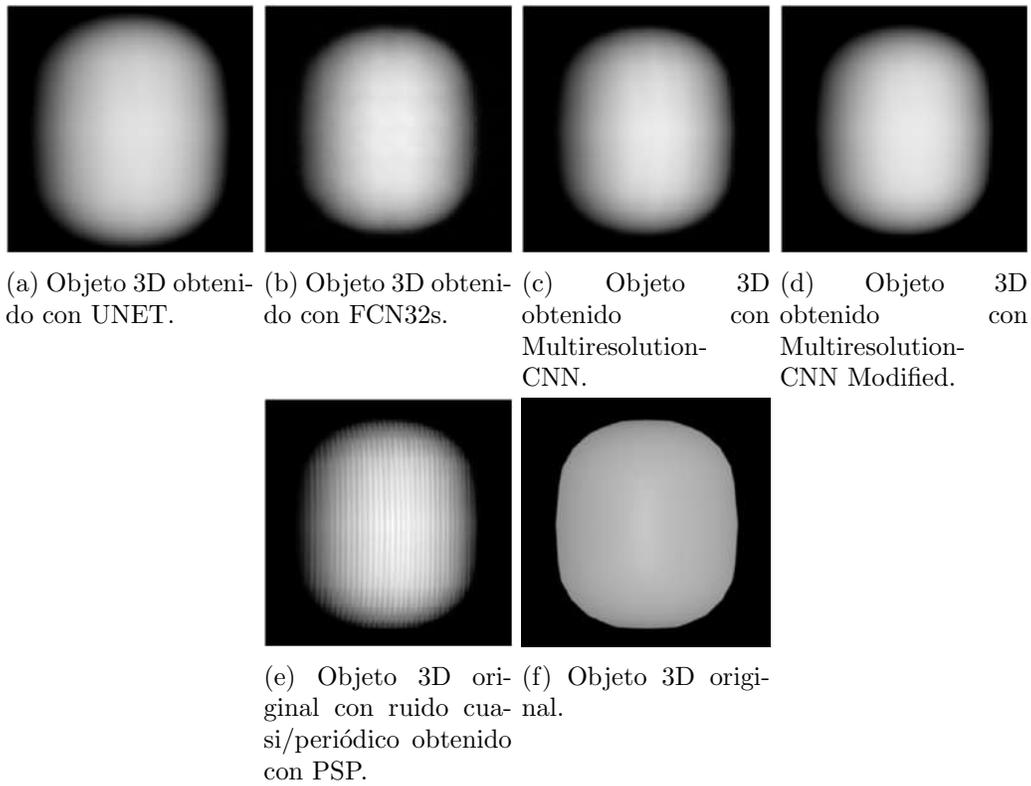


Figura 4.21: Reconstrucción de objeto 3D obtenido con diferentes arquitecturas de CNN y objeto original reconstruido con PSP.

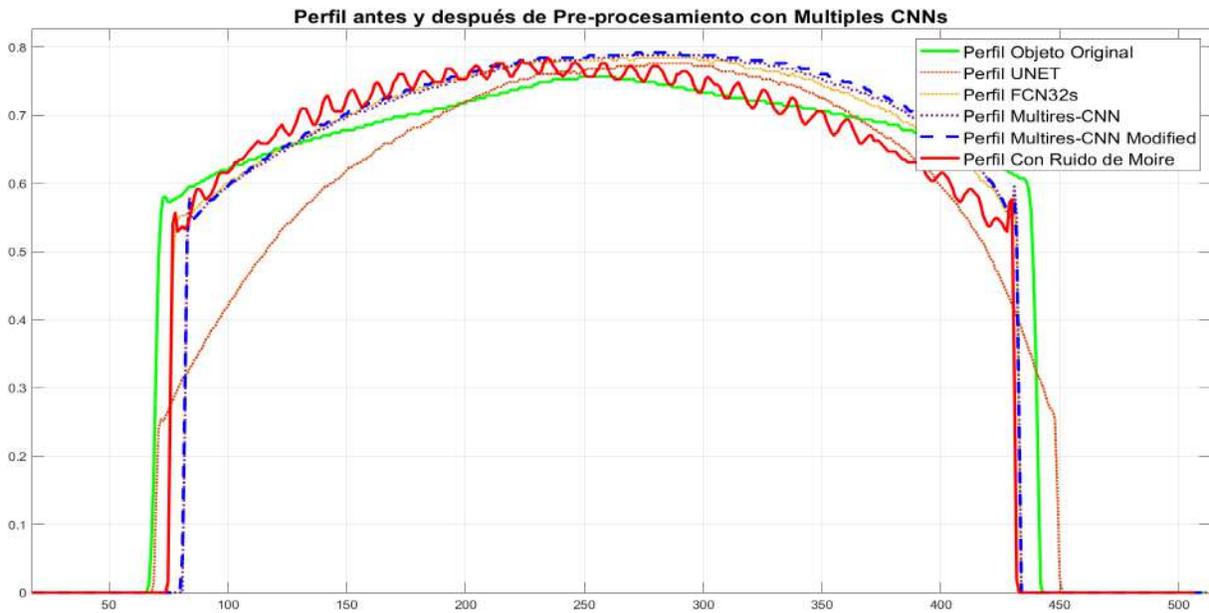


Figura 4.22: Análisis de perfil antes y después de procesamiento con redes entrenadas seleccionadas.

entrenado muestra la similitud de los objetos reconstruidos comparados con el objeto 3D original, como se muestra en las imágenes de la figura 4.23, para los cuales se ha realizado un escalamiento [45] de los objetos 3D inferidos para realizar comparación con el objeto original.

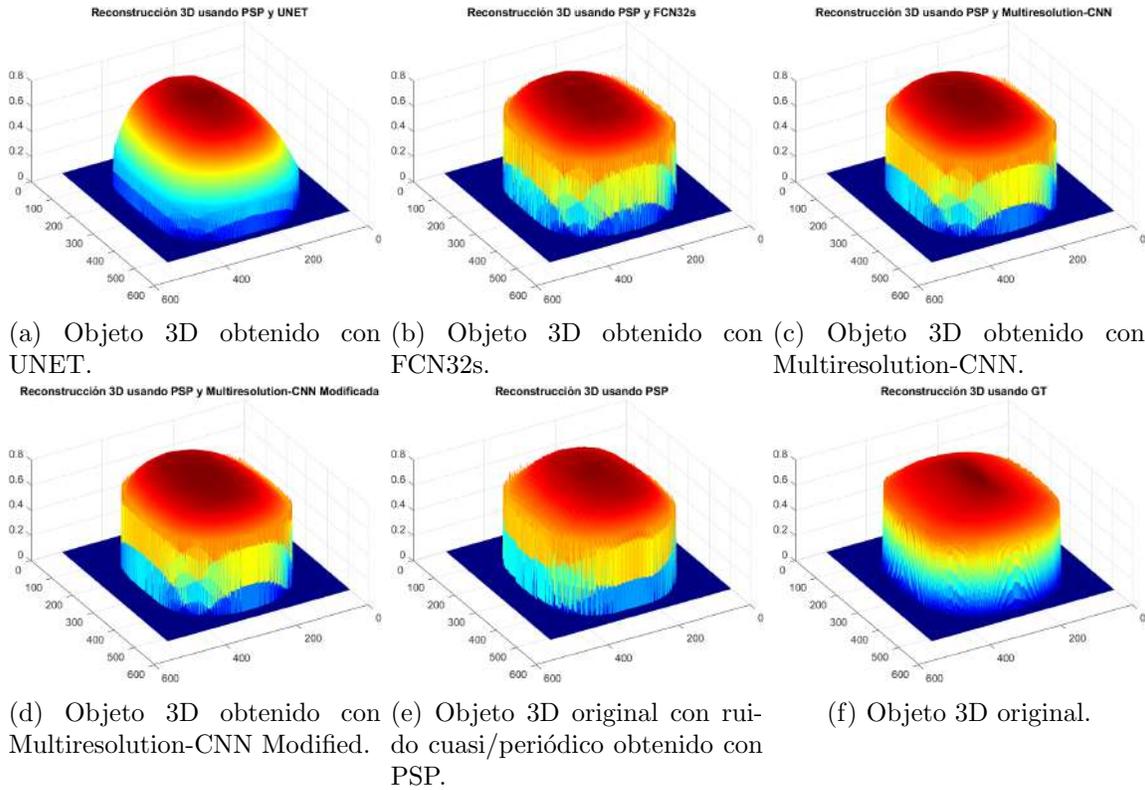


Figura 4.23: Reconstrucciones de objeto 3D obtenido con diferentes arquitecturas de CNN, objeto 3D original con ruido y objeto 3D original.

4.7. Resultados de entrenamiento usando mejores parámetros por cada modelo de red.

Los mejores parámetros se usaron obtenidos de los autores originales de cada arquitectura seleccionada, los cuales son mostrados en la tabla 4.6, realizando adecuaciones para utilizar los parámetros acordes a la tarea de restauración de imágenes en lugar de la tarea originalmente empleada. Cabe aclarar que se hace uso de la arquitectura de cada modelo CNN únicamente. Por otro lado, se realizaron múltiples entrenamientos para encontrar los parámetros establecidos en la tabla 4.6, y todos se realizaron a prueba y error, dado que lo que realmente se buscaba era la mejor calidad visual del objeto, esto es que el ruido cuasi/periódico se atenuara completamente además de datos cuantitativos para corroborar la información. Por otro lado, la pérdida de información del objeto debía ser la menor posible, dado que era necesaria dicha información para reconstruir completamente el objeto 3D lo más suave y cercano posible al objeto original.

Parámetro	U-Net	FCN32s	Multires-CNN	Multires-CNN Modified
Tamaño de lote (batch-size)	4	8	8	32
Pesos iniciales (weights initials)	Aleatorio Gaussiano (Mean=0.0, std=0.01)	Pre-trained VGGNet)	Aleatorio Gaussiano (Mean=0.0, std=0.01)	Aleatorio Gaussiano (Mean=0.0, std=0.01)
Bias	0.0	0.0	0.0	0.0
Tasa de aprendizaje (rate learning)	1e-5	1e-4	1e-4	1e-4
Optimizador	RMSprop()	RMSprop()	Adam()	Adam()
Perdida por Entrenamiento	MSELoss()	BCEWith Logits-Loss()	MSELoss()	MSELoss()
Perdida por validación	MSELoss()	BCEWith Logits-Loss()	MSELoss()	MSELoss()
Plan de entrenamiento (train, val, test)	70 %, 10 %, 20 %	70 %, 10 %, 20 %	70 %, 10 %, 20 %	70 %, 10 %, 20 %
Tamaño de imágenes (Width, Height)	572×572 pixeles	512×512 pixeles	256×256 pixeles	256 × 256 pixeles
Cantidad de imágenes (Train)	276	276	276	276
Cantidad de imágenes (Val)	27	27	27	27
Cantidad de imágenes (Test)	69	69	69	69

Tabla 4.6: Parámetros usados durante el entrenamiento de redes para comparación

La evolución del entrenamiento de los modelos usando los parámetros de la tabla 4.6 son mostrados en las gráficas de la figura 4.24. En las gráficas se puede apreciar claramente como utilizando estos parámetros específicos por cada modelo se consigue un mejor aprendizaje del modelo entrenado final, además de que se observa como cada entrenamiento converge hacia un valor de pérdida que, de acuerdo con la literatura, indica un buen aprendizaje, además de otros factores.

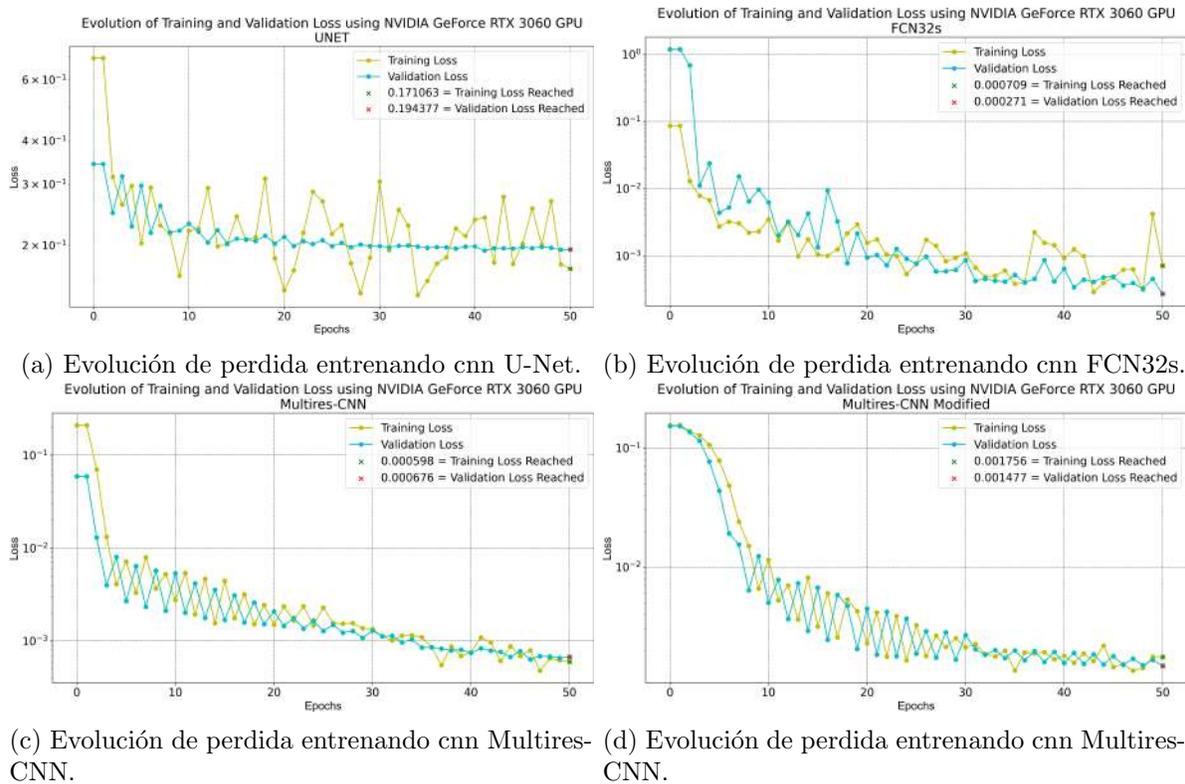


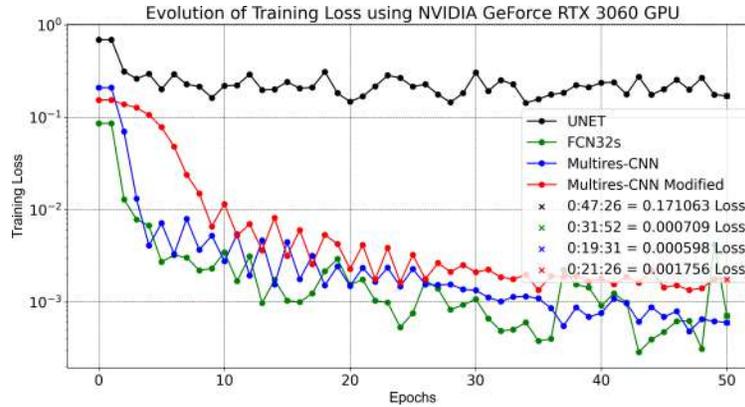
Figura 4.24: Evolución de pérdida por entrenamiento y por validación de cada red CNN entrenada.

Los valores de pérdida por entrenamiento y validación, además del tiempo de entrenamiento de cada modelo usado, además del propuesto usando los parámetros definidos en la tabla 4.6 son mostrados en la tabla 4.7.

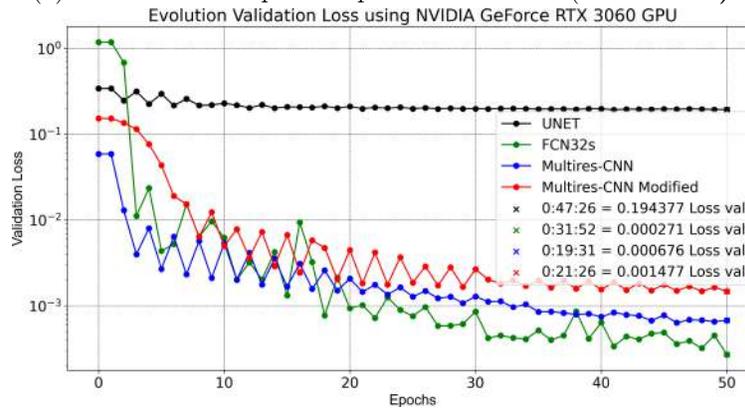
Tabla 4.7: Resultados del entrenamiento de redes para comparación con mejores parámetros encontrados para cada modelo CNN.

Resultados	UNet	FCN32s	Multires-CNN	Multires-CNN Modified
Perdida por entrenamiento(Loss train)	0.171063	0.000709	0.000598	0.001756
Perdida por validación (Loss val)	0.194377	0.000271	0.000676	0.001477
Tiempo de entrenamiento (HH:MM:SS)	00:47:26	00:31:52	00:19:31	00:21:26

La evolución de pérdida por entrenamiento y validación usando estos parámetros son mostrados en las gráficas 4.25 en conjunto para los 4 modelos CNN entrenados. Se observa como el modelo UNet tiene el peor rendimiento en este entrenamiento y bastante pérdida de información en las inferencias realizadas. Estas inferencias se pueden observar en las imágenes de la figura 4.26



(a) Evolución de la pérdida por entrenamiento(**Train Loss**).



(b) Evolución de la pérdida por validación(**Val Loss**).

Figura 4.25: Evolución de pérdida por entrenamiento y por validación de cada red CNN entrenada.

Las métricas cuantitativas de la tabla 4.8 muestran un mejor desempeño logrado con el modelo de red neuronal convolucional propuesto, además de los parámetros definidos después de una serie de pruebas.

Los resultados visuales pueden observarse en las imágenes de la figura 4.26, donde se puede apreciar en la parte aumentada como es atenuada exitosamente el ruido cuasi/periódico de las representaciones 2D de los objetos inferidos por los modelos CNN entrenados y el propuesto. Cabe resaltar una mayor atenuación de contaminación realizada por la arquitectura propuesta, así como una conservación mayor de los detalles del objeto.

Las reconstrucciones 3D de los objetos muestran una aproximación más cercana al objeto original después de realizar un escalamiento de las representaciones 2D con la arquitectura de red propuesta, además de reconstruir los objetos más suaves comparados con las demás reconstrucciones. Estos son mostrados en las imágenes de la figura 4.27.

Dado que las inferencias están restringidas al tamaño de salida de la red utilizada, no fue posible

Tabla 4.8: Métricas obtenidas a partir de objetos 3D resultantes de inferencias de diferentes arquitecturas CNNs.

CNN	PSNR	IMMSE	SSIM	MSE(Perfil)
Multiresolution -CNN Modified	14.4839	0.0356	0.7915	0.0332
UNET	8.4898	0.1416	0.5724	0.1573
FCN32s	14.5527	0.0351	0.7462	0.0331
Multiresolution-CNN	14.3431	0.0368	0.7839	0.0354

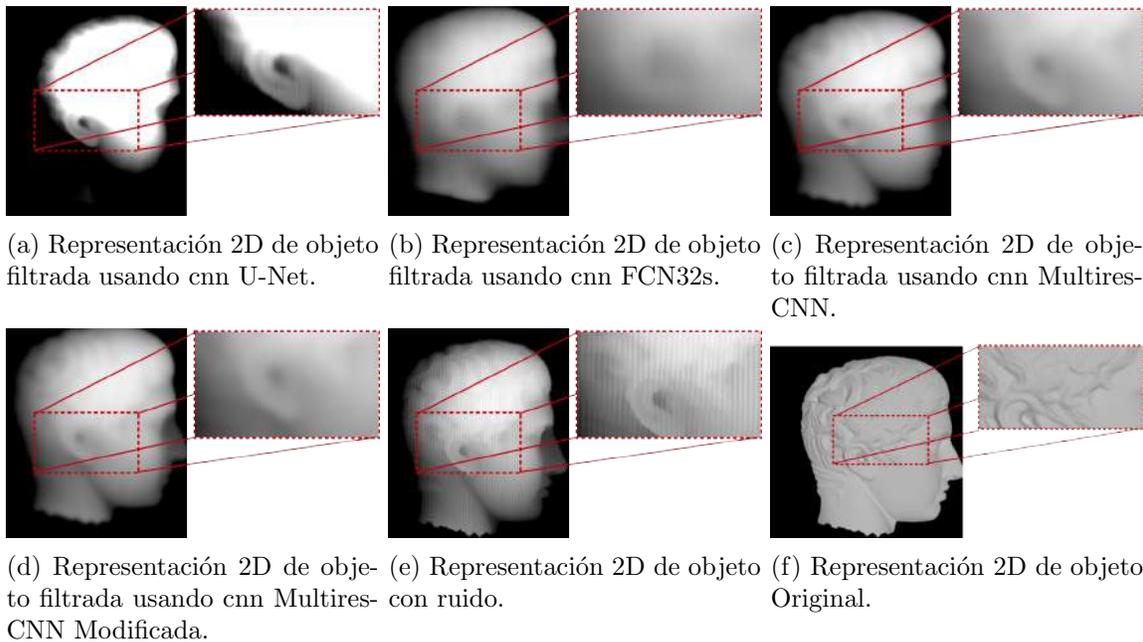


Figura 4.26: Vista cercana de objetos 3D después de ser procesado con múltiples CNN's y objeto con ruido cuasi/periódico.

obtener un perfil adecuado para un análisis de reconstrucción 3D, sin embargo, las reconstrucciones realizadas con las inferencias obtenidas y mostradas en la figura 4.27 se puede observar una reconstrucción del objeto más suave y parecido al objeto original. Esto se puede ver claramente en la reconstrucción de la figura 4.27d.

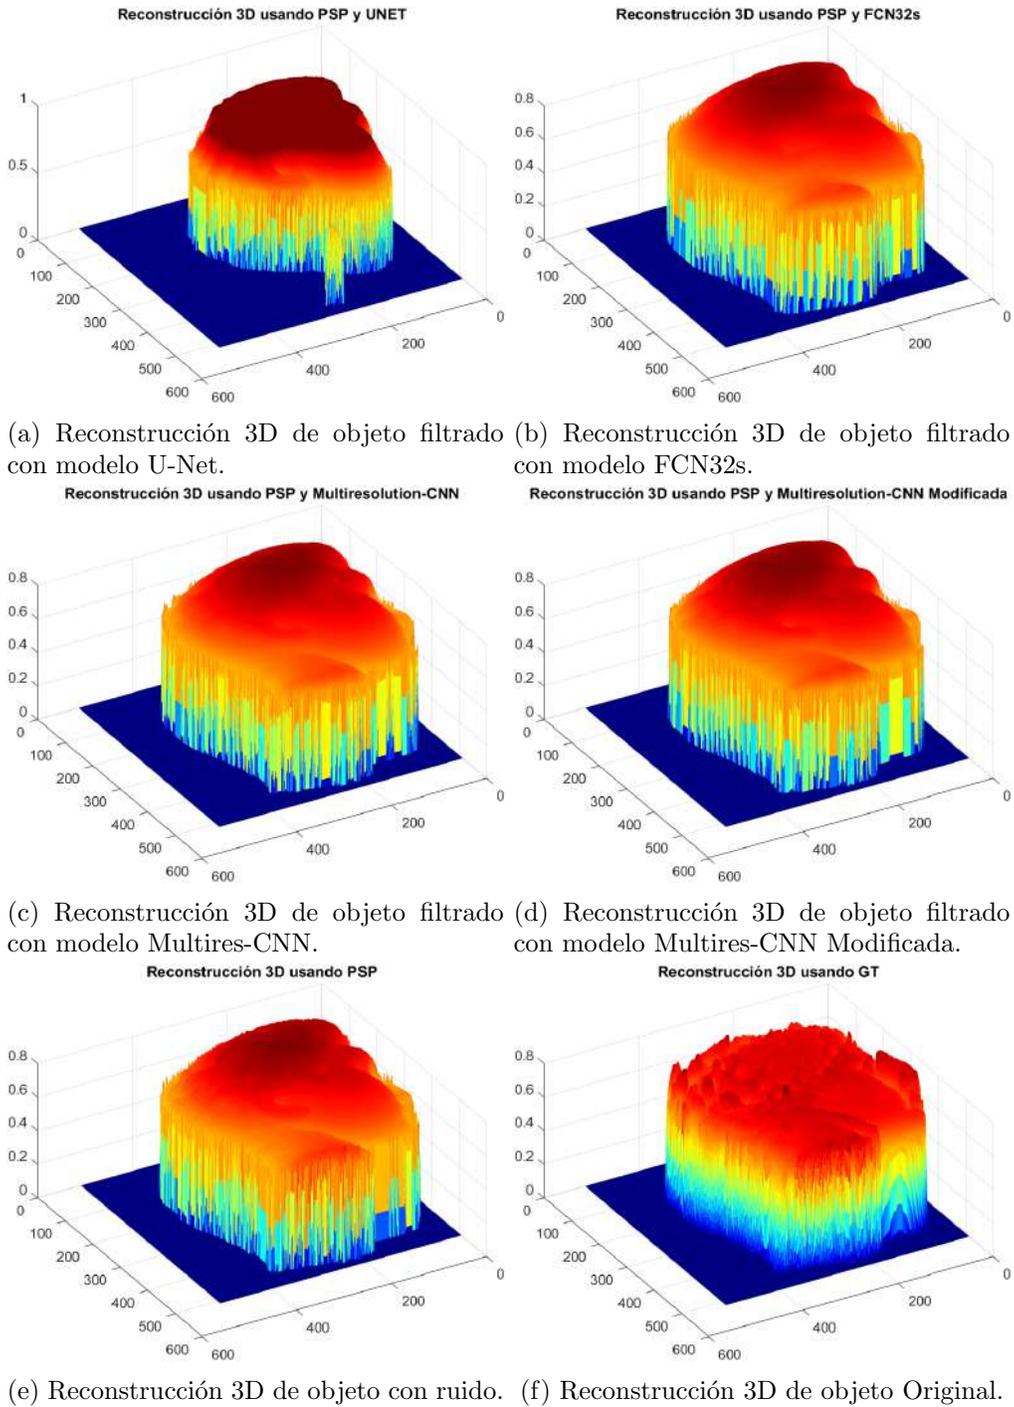
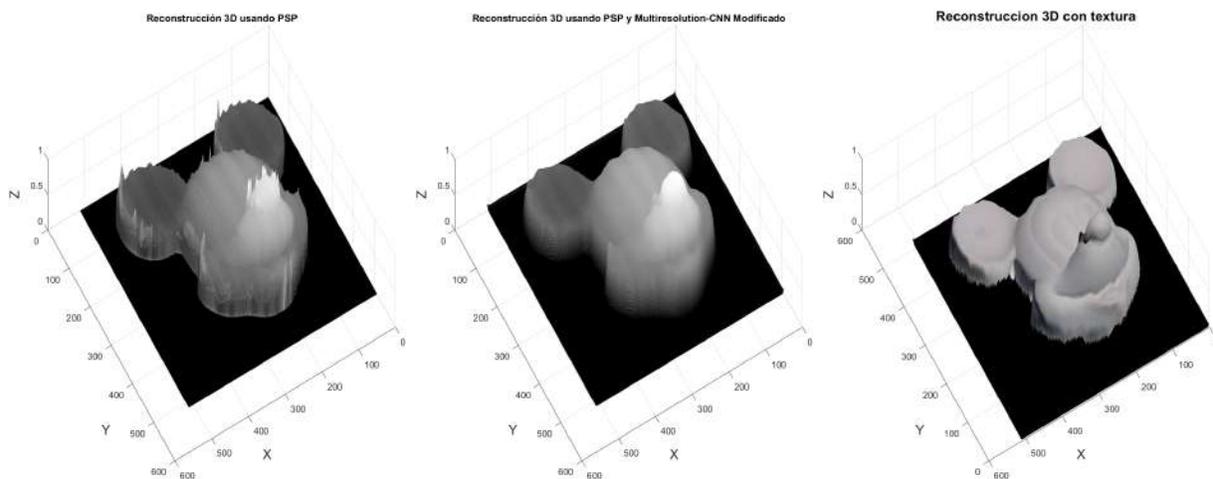


Figura 4.27: Vista cercana de objetos 3D después de ser procesado con múltiples CNN's y objeto con ruido cuasi/periódico.

4.8. Resultados con objetos reales

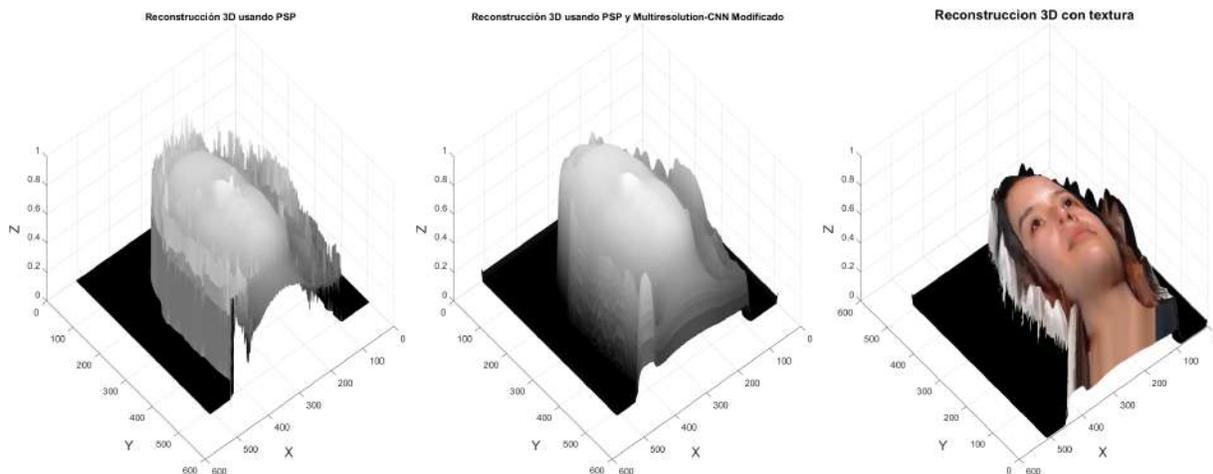
Para probar los modelos entrenados en atenuar el ruido cuasi/periódico en imágenes obtenidas mediante perfilometría de franjas, se usaron objetos reales obtenidos mediante esta técnica y el método de 3 pasos(3-Step). Una vez que se obtuvieron los mapas de fase y mapas de referencia, se obtuvieron los desentrollados los objetos que, una vez aplicando la máscara correspondiente a cada objeto, se obtienen las regiones de interés de los mismos. Como se aprecian en las imágenes de la figura 4.28 y 4.29. Aquí se puede apreciar los resultados inferidos por el modelo entrenado y la aplicación de la textura original de los objetos al resultado obtenido junto con el objeto obtenido mediante desentrollamiento de fase.



(a) Reconstrucción 3D de objeto usando PSP.

(b) Reconstrucción 3D de objeto con modelo Multiresolution-CNN Modified.

(c) Reconstrucción 3D de objeto con modelo Multiresolution-CNN Modified con textura.

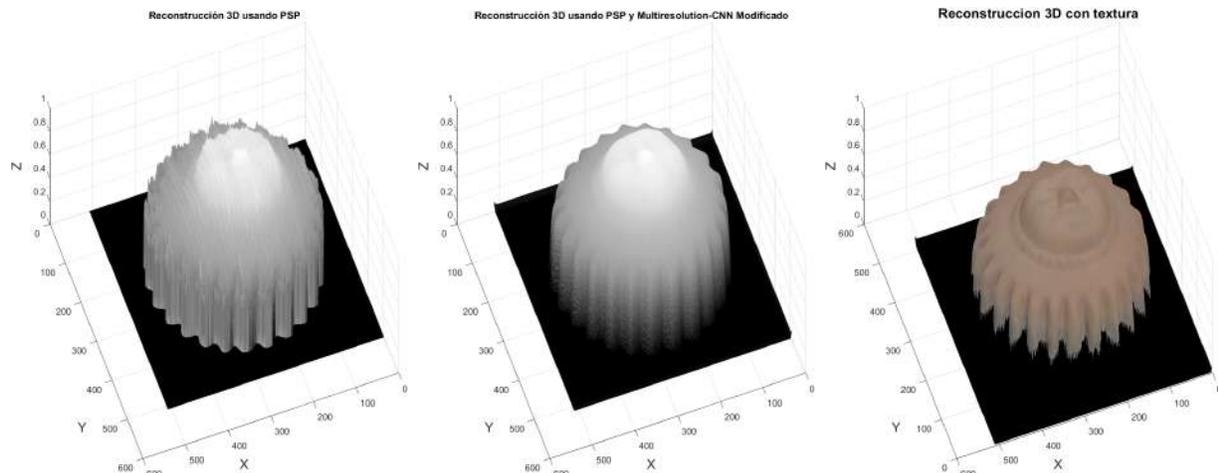


(d) Reconstrucción 3D de objeto usando PSP.

(e) Reconstrucción 3D de objeto con modelo Multiresolution-CNN Modified.

(f) Reconstrucción 3D de objeto con modelo Multiresolution-CNN Modified con textura.

Figura 4.28: Reconstrucción de objetos reales filtrados con modelo entrenado, parte 1.



(a) Reconstrucción 3D de objeto usando PSP. (b) Reconstrucción 3D de objeto con modelo Multiresolution-CNN Modified. (c) Reconstrucción 3D de objeto con modelo Multiresolution-CNN Modified con textura.

Figura 4.29: Reconstrucción de objetos reales filtrados con modelo entrenado, parte 2.

4.9. Importancia/Impacto

4.9.1. Impacto Social

El impacto social se puede ver hasta el momento en lo académico, debido a que la investigación aún se encuentra en curso; sin embargo, viendo al futuro se puede ver los siguientes:

- Generación de conocimiento para investigaciones posteriores.
- Generación de objetos y entornos de forma virtual y fieles al objeto y entornos reales.

4.9.2. Impacto Ambiental

El impacto ambiental resulta ser mínimo debido a que el desarrollo de la investigación se realizó de manera digital sin utilizar otros recursos materiales adicionales.

4.9.3. Impacto Económico

La utilización de software libre como **Blender** resulto un importante ahorro económico, ya que, al generar las imágenes para la base de datos de forma sintética, se prescindía de usar cámaras y proyectores reales. Por otro lado, el ahorro de tiempo también fue significativo, esto debido a que el sistema estaba integrado en un solo software, además de que no se utilizó personal adicional para la generación de las imágenes.

4.10. Publicaciones

Durante el desarrollo de esta tesis se redactaron los siguientes trabajos con número de referencia ORCID: <https://orcid.org/0000-0002-6730-2009>, siendo de autoría propia y como trabajo adicional

a la tesis lo siguiente:

1. Espinosa-Bernal, O. A., Pedraza-Ortega, J. C., Aceves-Fernández, M. A., Martínez-Suárez, V. M., & Tovar-Arriaga, S. (2022). Adaptive Based Frequency Domain Filter for Periodic Noise Reduction in Images Acquired by Projection Fringes. In International Congress of Telematics and Computing (pp. 18-32). Springer, Cham. https://doi.org/10.1007/978-3-031-18082-8_2.

Y colaborador en el siguiente trabajo:

1. Martínez-Suárez, V. M., Pedraza-Ortega, J. C., Salazar-Colores, S., Espinosa-Bernal, O. A., & Ramos-Arreguin, J. M. (2022). Environment Emulation in 3D Graphics Software for Fringe Projection Profilometry. In International Congress of Telematics and Computing (pp. 122-138). Springer, Cham. https://doi.org/10.1007/978-3-031-18082-8_8

Ambos trabajos fueron presentados y publicados en el congreso "The 11th International Congress in Telematics and Computing" WITCOM 2022.

Este trabajo fue apoyado en parte por el Consejo Nacional de Ciencia y Tecnología (CONACyT), México, en el Posgrado Facultad de Ingeniería por la Universidad Autónoma de Querétaro, bajo Beca CVU 1099050.

4.11. Trabajo a futuro

Como trabajo futuro se tienen diversas áreas de oportunidad tanto en la parte de generación de imágenes para generar bases de datos, pasando por la mejora de algoritmos de preprocesamiento de las imágenes obtenidas hasta el mejoramiento del entrenamiento de redes neuronales convolucionales.

1. Generación de base de datos de imágenes con un mayor número de las mismas.
2. Mejoramiento del sistema emulado para conseguir las mejores escenas de objetos.
3. Automatización del sistema de generación de las imágenes.
4. Mejoramiento del algoritmo de reducción de ruido cuasi/periódico en imágenes contaminadas.
5. Búsqueda de mejoras con redes neuronales convolucionales aplicados.
6. Aplicación de los modelos entrenados a aplicaciones reales.

Entre otras oportunidades que puedan ser desarrollados.

Conclusiones

La obtención de objetos 3D a partir de lo que observa una computadora en su entorno es una área de inteligencia artificial de la visión por computadora que más investigación ha tenido recientemente. Lo hace de manera que sea capaz de determinar profundidad a partir de información 2D de los objetos y entorno observados. Existen numerosas técnicas para obtener la información 3D a partir de sus representaciones 2D o directamente del objeto. Esta tesis se basa en la técnica conocida como PSP (Phase-Shifting Profilometry) específicamente de 3 pasos(3-Step) el cual es una técnica de no contacto y trabaja a partir de imágenes, utilizando un sistema que consiste en la proyección de un patrón de franjas sobre un objeto 3D y recuperando la información mediante la extracción de fase y desenvolvimiento de la fase generando una reconstrucción 3D.

El trabajo que se presenta en esta tesis tiene como objetivo describir en detalle un sistema de emulación del sistema de PSP haciendo uso del software libre *Blender* para la generación de las imágenes a partir de las cuales se obtendrá, mediante la extracción de fase y desenvolvimiento de la fase, un objeto 3D. Con esto se consigue un sistema que es capaz de replicar un sistema real para la obtención de imágenes y usar la técnica PSP. Por otro lado, este sistema de perfilometría de superficie permite desarrollar una técnica que atenúa el ruido de Moire producido durante la generación de las imágenes y con esto desarrollar una base de datos que, una vez desarrollada, una red neuronal convolucional de aprendizaje profundo, permite atenuar dicho ruido de Moire usando únicamente el modelo entrenado.

Como primera contribución se desarrolla un algoritmo que atenúa el ruido generado durante la adquisición de las imágenes en el dominio de la frecuencia. Este ruido que interfiere en la reconstrucción de los objetos 3D es conocido como ruido de Moire y está asociado a patrones presentes en imágenes, y, por lo tanto, ya que se trabaja con una proyección de patrón de franjas, la contaminación está presente en la técnica utilizada.

Como segunda contribución se presenta el desarrollo de una arquitectura de red neuronal convolucional que permite, mediante el entrenamiento con imágenes contaminadas y procesadas con el algoritmo propuesto e implementado, automatizar la tarea de eliminar el ruido presente en los objetos 3D reconstruidos, generando de esta manera objetos 3D más suaves y parecidos al objeto real.

Los resultados obtenidos muestran una reconstrucción de objetos 3D más suaves y precisos similares al objeto original. Esto fue probado en objetos con similitud a rostros humanos y objetos más simples para verificar su rendimiento, tanto cualitativos como cuantitativos, utilizando para las mediciones las métricas PSNR, IMMSE, SSIM y MSE(Profile).

Finalmente, al probar objetos reales con la metodología desarrollada se observa que consigue atenuar el ruido cuasi/periódico presente en imágenes obtenido mediante un sistema convencional de imágenes, esto con un proyector de patrones y cámara reales, consiguiendo que a partir del uso de imágenes sintéticas, se pueda procesar imágenes reales, evitando la costosa tarea de adquirir imágenes de manera tradicional.

En conclusión, este trabajo muestra el desarrollo e implementación de una metodología para obtener objetos 3D a partir de imágenes 2D usando un sistema emulado para la adquisición de imágenes con el método PSP de 3 pasos (3-Step), el desarrollo de un algoritmo de filtrado de ruido cuasi/periódico que realiza la operación de manera tradicional procesando la imagen en el dominio de la frecuencia y el desarrollo y entrenamiento de una red neuronal convolucional de aprendizaje profundo, consiguiendo de esta manera objetos 3D reconstruidos similares a los objetos 3D originales, usando I.A. para atenuar el ruido cuasi/periódico de forma exitosa, además de ser probado exitosamente en imágenes reales adquiridas con proyector y cámara físicos.

Bibliografía

- [1] C. Rocchini, P. Cignoni, C. Montani, P. Pinci, and R. Scopigno, “A low cost 3d scanner based on structured light,” in *computer graphics forum*, vol. 20, pp. 299–308, Wiley Online Library, 2001.
- [2] V. Martínez-Suárez, J. Pedraza-Ortega, S. Salazar-Colores, O. Espinosa-Bernal, and J. Ramos-Arreguin, “Environment emulation in 3d graphics software for fringe projection profilometry,” in *Telematics and Computing: 11th International Congress, WITCOM 2022, Cancún, México, November 7–11, 2022, Proceedings*, pp. 122–138, Springer, 2022.
- [3] R. E. Gonzalez CR, *Digital image processing*. Pearson Education, 2008.
- [4] M. Idesawa, T. Yatagai, and T. Soma, “Scanning moiré method and automatic measurement of 3-d shapes,” *Applied Optics*, vol. 16, no. 8, pp. 2152–2162, 1977.
- [5] M. Takeda and K. Mutoh, “Fourier transform profilometry for the automatic measurement of 3-d object shapes,” *Applied optics*, vol. 22, no. 24, pp. 3977–3982, 1983.
- [6] P. Ou, B. Li, Y. Wang, and S. Zhang, “Flexible real-time natural 2d color and 3d shape measurement,” *Optics express*, vol. 21, no. 14, pp. 16736–16741, 2013.
- [7] J. Geng, “Structured-light 3d surface imaging: a tutorial,” *Advances in Optics and Photonics*, vol. 3, no. 2, pp. 128–160, 2011.
- [8] J. C. Pedraza Ortega, J. W. Rodriguez Moreno, L. Barriga Rodriguez, E. Gorrostieta Hurtado, T. Salgado Jimenez, J. M. Ramos Arreguin, and A. Rivas, “Image processing for 3d reconstruction using a modified fourier transform profilometry method,” in *MICAI 2007: Advances in Artificial Intelligence: 6th Mexican International Conference on Artificial Intelligence, Aguascalientes, Mexico, November 4-10, 2007. Proceedings 6*, pp. 705–712, Springer, 2007.
- [9] C.-V. López-Torres, S. Salazar Colores, K. Kells, J.-C. Pedraza-Ortega, and J.-M. Ramos-Arreguin, “Improving 3d reconstruction accuracy in wavelet transform profilometry by reducing shadow effects,” *IET Image Processing*, vol. 14, no. 2, pp. 310–317, 2020.
- [10] B. Ribbens, V. Jacobs, J. Dirckx, S. Vanlanduit, and J. Buytaert, “Projection moire profilometry simulation software for algorithm validation and setup optimisation,” in *Proceedings of the 5th International Conference on Optical Measurement Techniques for Structures & Systems*, p. 349, 2013.

- [11] J. Fehrenbach, P. Weiss, and C. Lorenzo, “Variational algorithms to remove stationary noise: applications to microscopy imaging,” *IEEE transactions on image processing*, vol. 21, no. 10, pp. 4420–4430, 2012.
- [12] Z. Ji, Z. Ming, Q. Li, and Q. Wu, “Reducing periodic noise using soft morphology filter,” *Journal of Electronics (China)*, vol. 21, pp. 159–162, 2004.
- [13] T. Ji, Z. Lu, and Q. Wu, “Optimal soft morphological filter for periodic noise removal using a particle swarm optimiser with passive congregation,” *Signal Processing*, vol. 87, no. 11, pp. 2799–2809, 2007.
- [14] A. Rai, *An empirical study of periodic noise filtering in Fourier domain: an introduction to novel autonomous periodic noise removal algorithms*. Lap Lambert Academic Publishing, 2013.
- [15] R. Srinivasan, M. Cannon, and J. White, “Landsat data destriping using power spectral filtering,” *Optical Engineering*, vol. 27, no. 11, pp. 939–943, 1988.
- [16] M. Lebrun, M. Colom, A. Buades, and J.-M. Morel, “Secrets of image denoising cuisine,” *Acta Numerica*, vol. 21, pp. 475–576, 2012.
- [17] P. Milanfar, “A tour of modern image filtering: New insights and methods, both practical and theoretical,” *IEEE signal processing magazine*, vol. 30, no. 1, pp. 106–128, 2012.
- [18] I. Aizenberg and C. Butakoff, “A windowed gaussian notch filter for quasi-periodic noise removal,” *Image and Vision Computing*, vol. 26, no. 10, pp. 1347–1353, 2008.
- [19] P. Moallem, M. Masoumzadeh, and M. Habibi, “A novel adaptive gaussian restoration filter for reducing periodic noises in digital image,” *Signal, image and video processing*, vol. 9, pp. 1179–1191, 2015.
- [20] Z. Wei, J. Wang, H. Nichol, S. Wiebe, and D. Chapman, “A median-gaussian filtering framework for moiré pattern noise removal from x-ray microscopy image,” *Micron*, vol. 43, no. 2-3, pp. 170–176, 2012.
- [21] L. A. Alvarado Escoto, J. C. P. Ortega, J. M. Ramos Arreguin, E. Gorrostieta Hurtado, and S. Tovar Arriaga, “The effect of bilateral filtering in 3d reconstruction using psp,” in *Tele-matics and Computing: 9th International Congress, WITCOM 2020, Puerto Vallarta, Mexico, November 2–6, 2020, Proceedings 9*, pp. 268–280, Springer, 2020.
- [22] J. Varghese, “Adaptive threshold based frequency domain filter for periodic noise reduction,” *AEU-international journal of electronics and communications*, vol. 70, no. 12, pp. 1692–1701, 2016.
- [23] L. Karacan, E. Erdem, and A. Erdem, “Structure-preserving image smoothing via region covariances,” *ACM Transactions on Graphics (TOG)*, vol. 32, no. 6, pp. 1–11, 2013.
- [24] S. Ono, T. Miyata, and I. Yamada, “Cartoon-texture image decomposition using blockwise low-rank texture characterization,” *IEEE Transactions on Image Processing*, vol. 23, no. 3, pp. 1128–1142, 2014.

- [25] J. Ok, S. Youn, G. Seo, E. Choi, Y. Baek, and C. Lee, “Paper check image quality enhancement with moire reduction,” *Multimedia Tools and Applications*, vol. 76, pp. 21423–21450, 2017.
- [26] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017.
- [27] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [28] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9, 2015.
- [29] C. Dong, C. C. Loy, K. He, and X. Tang, “Learning a deep convolutional network for image super-resolution,” in *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part IV 13*, pp. 184–199, Springer, 2014.
- [30] M. Gharbi, G. Chaurasia, S. Paris, and F. Durand, “Deep joint demosaicking and denoising,” *ACM Transactions on Graphics (ToG)*, vol. 35, no. 6, pp. 1–12, 2016.
- [31] K. Zhang, W. Zuo, S. Gu, and L. Zhang, “Learning deep cnn denoiser prior for image restoration,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3929–3938, 2017.
- [32] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, “Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising,” *IEEE transactions on image processing*, vol. 26, no. 7, pp. 3142–3155, 2017.
- [33] Y. Sun, Y. Yu, and W. Wang, “Moiré photo restoration using multiresolution convolutional neural networks,” *IEEE Transactions on Image Processing*, vol. 27, no. 8, pp. 4160–4172, 2018.
- [34] T. Yoshizawa, *Handbook of optical metrology: Principles and Applications*. CRC press, 2009.
- [35] T. Tao, Q. Chen, S. Feng, Y. Hu, J. Da, and C. Zuo, “High-precision real-time 3d shape measurement using a bi-frequency scheme and multi-view system,” *Applied optics*, vol. 56, no. 13, pp. 3646–3653, 2017.
- [36] X. Su and W. Chen, “Fourier transform profilometry:: a review,” *Optics and lasers in Engineering*, vol. 35, no. 5, pp. 263–284, 2001.
- [37] H. Schreiber and J. H. Bruning, “Phase shifting interferometry,” *Optical shop testing*, pp. 547–666, 2007.
- [38] S. S. Gorthi and P. Rastogi, “Fringe projection techniques: whither we are?,” *Optics and lasers in engineering*, vol. 48, no. ARTICLE, pp. 133–140, 2010.
- [39] T. Yoshizawa, *Handbook of optical metrology: Principles and Applications*. CRC press, 2009.
- [40] J. Garcia, “Review in digitization of solid through structured light,” *Centro de investigaciones en optica, AC*, 2015.

- [41] F. Wang, C. Wang, and Q. Guan, “Single-shot fringe projection profilometry based on deep learning and computer graphics,” *Optics Express*, vol. 29, no. 6, pp. 8024–8040, 2021.
- [42] J. M. Bioucas-Dias and G. Valadao, “Phase unwrapping via graph cuts,” *IEEE Transactions on Image processing*, vol. 16, no. 3, pp. 698–709, 2007.
- [43] F. Liu, J. Yang, and H. Yue, “Moiré pattern removal from texture images via low-rank and sparse matrix decomposition,” in *2015 Visual Communications and Image Processing (VCIP)*, pp. 1–4, IEEE, 2015.
- [44] O. Espinosa-Bernal, J. Pedraza-Ortega, M. Aceves-Fernández, V. Martínez-Suárez, and S. Tovar-Arriaga, “Adaptive based frequency domain filter for periodic noise reduction in images acquired by projection fringes,” in *Telematics and Computing: 11th International Congress, WITCOM 2022, Cancún, México, November 7–11, 2022, Proceedings*, pp. 18–32, Springer, 2022.
- [45] A. M. J. Gustavo, P. O. J. Carlos, A. Fernández, and M. Antonio, “Reconstrucción tridimensional de objetos sintéticos mediante desplazamiento de fase,”
- [46] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5–9, 2015, Proceedings, Part III 18*, pp. 234–241, Springer, 2015.
- [47] J. Long, E. Shelhamer, and T. Darrell, “Fully convolutional networks for semantic segmentation,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431–3440, 2015.

.1. Registro de protocolo de investigación



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
 DIVISIÓN DE INVESTIGACIÓN Y POSGRADO

REGISTRO DEL PROTOCOLO DE INVESTIGACIÓN DEL ESTUDIANTE DE POSGRADO

Los 2 Espados oscuros exclusivos para la Dirección	No. Registro de Proyecto*: Fecha de Registro*:	12579 22-06-2021
	Fecha de inicio de proyecto:	11/ENE/2021
	Fecha de término de proyecto:	16/DIC/2022
1. DATOS DEL SOLICITANTE		
No. de expediente:	302396	
Apellido Paterno	Apellido Materno	Nombre(s)
ESPINOSA	BERNAL	OSMAR ANTONIO
Dirección:		
Calle y número	Colonia	C.P.
Av. Hidalgo #137	Centro	76030
Estado	Teléfono (incluir lada)	Correo Electrónico
22	7151020886	antonio.be565@gmail.com
2. DATOS DEL PROYECTO		
Facultad:	INGENIERÍA	
Programa:	MAESTRIA EN CIENCIAS EN INTELIGENCIA ARTIFICIAL	
Tema específico del proyecto:	Reduccion de ruido periodico en imágenes obliendas por perflimtria usando tecnicas de aprendizaje profundo para reconstrucción de objetos 3D	
 PEDRAZA ORTEGA JESUS CARLOS Director de tesis	 TOVAR ARRIAGA SAUL Coordinador de programa	 ESPINOSA BERNAL OSMAR ANTONIO Alumno
Dr. Juan Carlos Jáuregui Correa Jefe de División de Investigación y Posgrado de la Fac. de Ing.	 Dr. Manuel Toledano Ayala Director de Fac. Ing.	 Dra. Ma. Guadalupe Flavia Lourca Piña Directora de Investigación y Posgrado UAQ



C.U., 10 de junio de 2021

Osmar Antonio Espinosa Bernal
Estudiante de Maestría en Ciencias en Inteligencia Artificial
Expediente 302396

Presente

El Comité de Ética Aplicada para la Investigación de la Facultad de Ingeniería ha revisado el protocolo del trabajo de tesis:

CEAIFI-095-2021-TP

**Reducción de ruido periódico en imágenes obtenidas por
perfilometría usando técnicas de aprendizaje profundo para
reconstrucción de objetos 3D**

Con apego a los lineamientos éticos de beneficencia, no maleficencia, justicia y autonomía, este comité ha dado el siguiente dictamen:

Exento de dictamen ético

El presente dictamen tiene vigencia de un año a partir de su fecha de emisión.

Sirva esta carta para los fines académicos que al interesado convengan.

Atentamente

"El Ingenio para Crear, No para Destruir"


Dra. Aurora Femat Díaz
Presidente del CEAIFI
afemat@uaq.mx



A QUIEN CORRESPONDA:

La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

ESPINOSA BERNAL OSMAR ANTONIO

Presentó el **Examen de Manejo de la Lengua** efectuado el día diecisiete de junio de dos mil veintidós, en el cual obtuvo la siguiente calificación:

8-

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día veintiocho de junio de dos mil veintidós.



Atentamente,
"Enlazar Culturas por la Palabra"

DRA. ADELINA VELÁZQUEZ HERRERA

AVH/japa*CL*FLL-C.-1214



A QUIEN CORRESPONDA:

La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

ESPINOSA BERNAL OSMAR ANTONIO

Presentó y acreditó el **Examen de Comprensión de Textos en Inglés** efectuado el día dieciocho de octubre de dos mil veintiuno.

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día veinticinco de octubre de dos mil veintiuno.



Atentamente,
"Enlazar Culturas por la Palabra"

DRA. ADELINA VELÁZQUEZ HERRERA

AVH/japa*CL*FLL-C.-2019



