

**MEJORAMIENTO DE LA CALIDAD DE IMÁGENES DE TOMOGRAFÍA
COMPUTARIZADA DE RAYOS-X IMPLEMENTANDO TÉCNICAS DE
SUPERRESOLUCIÓN.**

JULIÁN CAMILO ARAQUE GÓMEZ

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA**

2016

**MEJORAMIENTO DE LA CALIDAD DE IMÁGENES DE TOMOGRAFÍA
COMPUTARIZADA DE RAYOS-X IMPLEMENTANDO TÉCNICAS DE
SUPERRESOLUCIÓN.**

JULIÁN CAMILO ARAQUE GÓMEZ

**Trabajo de Grado para optar al título de
Ingeniero de Sistemas**

Director

HENRY ARGUELLO FUENTES

Ingeniero electricista, Ph.D.

Codirector

MIGUEL ÁNGEL MÁRQUEZ CASTELLANOS

Ingeniero de sistemas, Ms. (c).

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA**

2016

AGRADECIMIENTOS

El autor expresa su agradecimiento:

Al profesor HENRY ARGUELLO FUENTES, director del proyecto por sus enseñanzas y acompañamiento; por brindarme la oportunidad de trabajar en este proyecto.

A MIGUEL ÁNGEL MÁRQUEZ CASTELLANOS, codirector del proyecto por su apoyo, por su papel de guía, por sus recomendaciones y por su paciencia; por ser tanto mi tutor como un gran amigo, por demostrarme que una adversidad puede convertirse en una gran motivación.

A Dios porque ha estado conmigo a cada paso que doy, cuidándome y dándome
fortaleza para continuar.

A mis padres y mi hermana por su apoyo, amistad, consejos y amor; quienes a lo
largo de mi vida han velado por mi bienestar y educación siendo mi apoyo en todo
momento, agradezco que hayan depositado su entera confianza en mí. Son ellos
quienes me dan la fuerza necesaria para lograr mis metas.

A mi cucho, el del Sindicato B.E.B.E.

A Chepi, la luz de mi vida, gracias por ser mi más grande motivación.

A Ronald Velandia y su familia, por brindarme una amistad y un apoyo
incondicional, siempre alentándome a seguir adelante.

A todas las personas que han hecho parte de mi formación, brindándome su
apoyo y cariño.

A todos aquellos que han aportado a mi crecimiento como persona y profesional.

A todas las personas que siempre confiaron en mí sin importar las adversidades y
aquellas personas que nunca confiaron, ya que fueron de gran motivación para
seguir adelante.

JULIÁN CAMILO ARAQUE GÓMEZ

CONTENIDO

	pág.
INTRODUCCIÓN	13
1. OBJETIVOS.....	16
2. MARCO TEORICO	17
2.1 TOMOGRAFÍA COMPUTARIZADA.....	17
2.1.1. Clasificación de tomógrafos.....	19
2.1.2. Adquisición de datos.....	23
2.2. SUPERRESOLUCIÓN.....	27
2.2.1. Superresolución por una imagen.....	29
2.2.2. Superresolución por múltiples imágenes..	29
2.2.3. Superresolución por entrenamiento de diccionarios..	30
2.2.4. Superresolución en imágenes CT.....	31
3. METODOS TRADICIONALES DE SUPERRESOLUCIÓN.....	34
3.1. INTERPOLACIÓN LANCZOS.....	34
3.2. SIMILITUD ENTRE VECINOS LOCALES (NON-LOCAL MEANS -NLM)	34
3.3. REGRESIÓN DE NÚCLEO DE DIRECCIONES	36
4. MÉTODO DE SUPERRESOLUCIÓN PROPUESTO	38
4.1. PLANTEAMIENTO MATEMÁTICO	38
4.2. ALGORITMO PROPUESTO DE SR PARA CT.....	38
5. SIMULACIONES Y RESULTADOS	40
5.1. AJUSTES EXPERIMENTALES	41
5.2. RESULTADOS	41
5.3. ANALISIS COMPUTACIONAL.....	54
6. CONCLUSIONES	57
7. RECOMENDACIONES	58
CITAS BIBLIOGRAFICAS	59

LISTA DE TABLAS

	pág.
Tabla 1: Algoritmo de superresolución para imágenes CT.	39
Tabla 2: Resultados cuantitativos imágenes CT	42
Tabla 3: Resultados error relativo entre la imagen original y los métodos implementados.	43
Tabla 4: Tiempo de reconstrucción para los métodos tradicionales y el método propuesto, con dimensiones espaciales específicas.	54
Tabla 5: Tiempo de reconstrucción para los métodos tradicionales y el método propuesto, con dimensiones transversales específicas.	55

LISTA DE FIGURAS

	pág.
Figura 1: Proceso de adquisición de un escáner de rayos-X.	17
Figura 2: Modelo matemático de la atenuación monocromática de rayos X.	18
Figura 3: Representación gráfica de un tomógrafo.	18
Figura 4: Tomógrafos, Grossmann y Siregraph.	20
Figura 5: Primera generación de tomógrafos.	21
Figura 6: Segunda generación de tomógrafos.	21
Figura 7: Tercera generación de tomógrafos.	22
Figura 8: Cuarta generación de tomógrafos.	22
Figura 9: Función Dirac y su representación en el dominio Radón.	24
Figura 10: Muestreo en dos dimensiones de un objeto en CT.	26
Figura 11: Representación matricial del modelo de captura CT.	27
Figura 12: Restauración de una imagen por métodos de SR.	28
Figura 13: Representación esquemática de SR con una sola imagen.	29
Figura 14: Representación de SR por múltiples imágenes.	30
Figura 15: Representación de SR por entrenamiento de diccionarios.	31
Figura 16: Objeto binario representado en una cuadrícula.	32
Figura 17: Superresolución de imágenes de tomografía computarizada	33
Figura 18: Interpolación Lanczos	35
Figura 19: Eliminación de ruido por cálculo de píxeles cercanos	36
Figura 20: Propagación del núcleo en datos muestreados uniformemente	37
Figura 21: Escáner General Electric Discovery ST PET/CT 600	40
Figura 22: Reconstrucciones imagen CT Caso 3.	43
Figura 23: Reconstrucciones imagen CT Cubo.	44
Figura 24: Reconstrucciones imagen CT Shepp-Logan Phantom	44
Figura 25: Error absoluto entre las imágenes reconstruidas y la imagen original Caso 3.	45

Figura 26:	Error absoluto entre las imágenes reconstruidas y la imagen original Cubo.	46
Figura 27:	Error absoluto entre las imágenes reconstruidas y la imagen original Shepp-Logan Phantom.	47
Figura 28:	Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje x de la imagen CT Caso 3.	48
Figura 29:	Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje x de la imagen CT Cubo.	49
Figura 30:	Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje x de la imagen CT Shepp-Logan Phantom.	50
Figura 31:	Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje transversal de la imagen CT Caso 3.	51
Figura 32:	Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje transversal de la imagen CT Cubo.	52
Figura 33:	Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje transversal de la imagen CT Shepp-Logan Phantom.	53
Figura 34:	Representación gráfica del tiempo de reconstrucción, correspondiente a la tabla 4	55
Figura 35:	Representación gráfica del tiempo de reconstrucción, correspondiente a la tabla 5	56

RESUMEN

TÍTULO: MEJORAMIENTO DE LA CALIDAD DE IMÁGENES DE TOMOGRAFÍA COMPUTARIZADA DE RAYOS-X IMPLEMENTANDO TÉCNICAS DE SUPERRESOLUCIÓN*

AUTOR: Julián Camilo Araque Gómez**

PALABRAS CLAVE: Tomografía computarizada, superresolución y Regresión de núcleo de direcciones.

DESCRIPCIÓN:

La tomografía computarizada (CT, de su sigla en inglés) es una técnica no invasiva de rayos-X, que por medio de la adquisición de cortes transversales, permite determinar la densidad y estructura interna de un objeto. Las adquisiciones transversales son llamadas comúnmente imágenes CT y debido a sus características representan un gran impacto en diferentes áreas de la investigación. Dado a que en ciertas aplicaciones, como medicina e industria de hidrocarburos, son necesarias imágenes CT de alta resolución (HR, de su sigla en inglés) para la detección y clasificación de las propiedades físicas de un objeto. Por lo tanto, ha surgido un gran interés en las técnicas de post-procesamiento como superresolución para obtener imágenes de HR a partir de imágenes de baja resolución. Sin embargo, los métodos tradicionales de superresolución (SR, de su sigla en inglés) en imágenes CT ignoran la información correlacionada contenida en los cortes transversales. En este trabajo se propone un método de superresolución para obtener imágenes CT de alta resolución a partir de su versión de baja resolución. El método propuesto se basa en un enfoque de reconstrucción que aprovecha la información de los cortes transversales correlacionados, mediante el uso de interpoladores cúbicos y filtros. Se obtienen mejoras de hasta 2 dB en términos de PSNR sobre los resultados obtenidos utilizando algoritmos tradicionales.

* Proyecto de grado.

** Facultad de Ingenierías Físico – Mecánicas. Escuela de Ingeniería de Sistemas e Informática.

Director: Henry Arguello Fuentes

ABSTRACT

TITLE: IMPROVING THE QUALITY OF CT IMAGES OF X-RAY BY THE IMPLEMENTATION OF SUPER-RESOLUTION TECHNIQUES*

AUTHORS: Julián Camilo Araque Gómez**

KEYWORDS: Computed tomography, Super-resolution and steering kernel regression.

DESCRIPTION:

Computed tomography (CT) is a non-invasive X-ray technique that, through the acquisition of cross sections, can determine object's density and internal structure. The transversal acquisitions are commonly called CT images and, due to their characteristics represent a great impact on different areas of research. Given that in certain applications, such as medicine and O&G industry, are necessary CT images of high resolution (HR) for detection and classification of the physical properties of an object. Therefore, there has been great interest in post-processing techniques such as super-resolution to produce HR images from low resolution images (LR). However, traditional methods of super-resolution (SR) on CT images ignore the correlated information contained in the cross sections. This work presents a method of super-resolution is proposed for high-resolution CT images from low-resolution version. The proposed method is based on a reconstruction approach takes advantage of the correlated information transverse cuts, using interpolators and cubic filters. Improvements of up to 2 dB is obtained in terms of PSNR of the results obtained using traditional algorithms.

* Research degree Project.

** Faculty of Physical-Mechanical Engineering. School Systems Engineering and Computer Science.

Director: Henry Arguello Fuentes.

INTRODUCCIÓN

La tomografía computarizada (CT) es una técnica no destructiva que permite la visualización de la estructura interna de los objetos mediante la adquisición de imágenes en cortes transversales, para el análisis de su densidad y composición atómica [1]–[6]. CT se considera el primer método para adquirir imágenes no invasivas de la parte interior del cuerpo humano que no estuvieron sesgadas por superposición de distintas estructuras anatómicas. Esto es debido a la proyección de toda la información en un plano de la imagen, como se observa, típicamente, en fluoroscopia de rayos-X. Por lo tanto, CT produce imágenes de mucho mayor contraste en comparación con la radiografía convencional [7]. Debido a esto, las imágenes CT son indispensables en rutinas clínicas tales como traumatología, oncología, industria de los hidrocarburos, cardiología, odontología, entre otras [8]–[13]. Sin embargo la captura de estas imágenes requiere arquitecturas complejas.

Tradicionalmente, las imágenes CT son capturadas utilizando tomógrafos axiales computacionales, que se clasifican principalmente en cuatro generaciones[2], [14]. La primera generación, se basa en una geometría de haz de rayos-X paralelos y un único detector. En la segunda generación se utilizan 30 detectores y un tubo de rayos-X que genera múltiples haces y cada uno incide en un único detector del arreglo. La tercera generación de tomógrafos implementa un conjunto de detectores en forma de arco, que junto con el tubo de rayos-X, describen una rotación de 360 grados alrededor del objeto, y de esta manera elimina el movimiento de translación de las dos primeras generaciones. La cuarta generación de tomógrafos implementa un anillo de detectores fijos (entre 600 y 4800), y es el tubo de rayos-X el que gira alrededor del paciente, mejorando notoriamente el ajuste de los detectores [2], [14], [15].

Factores como las aberraciones ópticas, los cambios de ángulos de visión, el ruido generado por el sensor o los tiempos e intervalos de medición de los tomógrafos disminuyen la calidad de las imágenes. Por lo tanto, para obtener imágenes de CT de alta calidad se implementan escáneres de gama alta o se sobremuestra el objeto para obtener un mayor número de medidas. Sin embargo, en diferentes áreas de la investigación los pacientes o muestras no pueden ser expuestos a altas dosis de radiación. La radiación ionizante que se encuentra en los Rayos-X se define como la radiación que tiene la energía suficiente para desplazar electrones de las moléculas [16]. Los electrones libres producidos por este desplazamiento, a su vez, pueden dañar las células humanas. *National Research Council of the National Academies* define las dosis bajas como las que van desde casi cero a cerca de 100 milisievert (mSv). La dosis de radiación de una radiografía de tórax es de unos 0,1 mSv. En Estados Unidos, las personas están expuestas, en promedio, a aproximadamente 3 mSv de radiación ambiental al año [17]. Por tanto, para ayudar a contrarrestar la exposición injustificada en los procedimientos que se realizan, se

deben implementar principios básicos de protección contra la radiación, lo que implica justificar y optimizar los procedimientos [18]–[20]. Adicionalmente, el uso de tomógrafos de gama alta aumenta los costos de implementación. Debido a esto, ha surgido interés en el estudio de técnicas de postprocesamiento en imágenes CT, utilizando filtros bidimensionales, los cuales capturan la información relevante, para obtener imágenes de mayor resolución a partir de imágenes generadas por tomógrafos de baja resolución. Otro aspecto importante de estas técnicas, es que permiten disminuir los tiempos de exposición y se disminuye el riesgo de alterar las muestras. Sin embargo, los métodos tradicionales de superresolución (SR) en imágenes CT se enfocan en el mejoramiento de la resolución del detector o de los intervalos de captura [21]–[24].

La superresolución (SR por sus siglas en inglés) es un área de postprocesamiento que permite mejorar la calidad de las imágenes incluyendo las imágenes CT[21]. Los métodos de SR son actualmente un campo de investigación activo en tomografía computacional, ya que permiten obtener imágenes de alta resolución mediante la implementación de sensores de bajo costo en los tomógrafos. Diversas metodologías han sido desarrolladas para el problema de superresolución, entre las que se encuentra SR por una sola imagen, múltiples imágenes y entrenamiento de diccionarios [23], [24]. Sin embargo, estos métodos ignoran la información contenida en los cortes transversales adyacentes, los cuales son un parámetro crucial para una reconstrucción óptima de alta resolución (HR por su sigla en inglés).

En este proyecto se plantea el desarrollo e implementación de un algoritmo de SR para el mejoramiento de la calidad de imágenes CT, tanto en su eje espacial como transversal. Mediante filtros tridimensionales, se aprovecha la información contenida en las dimensiones espacio-transversal para el mejoramiento y reconstrucción de los cortes transversales de la imagen. Este algoritmo permite obtener imágenes CT de alta resolución a partir de una versión de baja resolución, mediante la implementación de interpolaciones cúbicas y regresiones de núcleo de direcciones (SKR) [25], [26], con el fin de reducir costos en la arquitectura y los tiempos de exposición a la radiación. A diferencia de otros métodos de superresolución para imágenes CT, este enfoque obtiene imágenes de alta resolución sin información o formación de conjuntos adicionales de datos (PCA, diccionarios sobreentrenados, etc.) [27], [28]. Por otra parte, el algoritmo propuesto puede ser implementado en arquitecturas tradicionales de tomografía computarizada, lo cual es una ventaja sobre otras técnicas que requieren rediseño de la arquitectura de adquisición. Finalmente, los resultados serán analizados mediante su relación señal a pico ruido (Peak signal-to-noise ratio- PSNR) [24], [29], [30] y su error cuadrático medio (Mean square error - MSE).

Este documento se divide de la siguiente manera: en el capítulo 1 se introducen conceptos fundamentales que permiten el desarrollo del proyecto de grado, en el capítulo 2 se presentan tres modelos tradicionales de superresolución, interpolación 2D, interpolación 3D y el gradiente descendente, en el capítulo 3 se muestra el proceso de diseño del algoritmo de superresolución para imágenes de tomografía computarizada, en el capítulo 4 se exponen simulaciones y resultados obtenidos y finalmente se presentan las conclusiones.

1. OBJETIVOS

1.1 OBJETIVO GENERAL

Desarrollar e implementar un algoritmo para mejorar la calidad de las imágenes de tomografía computarizada utilizando técnicas de superresolución.

1.2 OBJETIVOS ESPECIFICOS

- Determinar una base de datos de imágenes de tomografía computarizada para realizar el mejoramiento de su calidad.
- Implementar un algoritmo de superresolución que permita mejorar la calidad de una imagen de tomografía computarizada de baja resolución, mediante la implementación de filtros tridimensionales.
- Implementar algoritmos de superresolución tradicionales en la literatura para el mejoramiento de la calidad de imágenes de tomografía computarizada.
- Determinar el rendimiento del método de superresolución desarrollado a través de la comparación con los métodos de mejoramiento de imágenes de la literatura.

2. MARCO TEORICO

2.1 TOMOGRAFÍA COMPUTARIZADA

La tomografía computarizada (CT por su sigla en inglés) es una técnica no destructiva que permite reconstruir la estructura interna de un objeto 3D, mediante la captura de imágenes 2D [2]. Debido a que las imágenes CT permiten analizar la densidad y composición atómica de los objetos contenidos en una escena, son indispensables tanto en aplicaciones científicas como comerciales, tales como geología, paleontología, odontología, arqueología, entre otras [1]–[4], [8], [9], [31]. Sin embargo, estas imágenes han tenido un mayor impacto en las áreas de medicina y exploración de hidrocarburos [1], [3]–[5], [8]–[13], [15], [32], [33].

Las imágenes CT son un conjunto de imágenes bidimensionales que contienen información de una escena a lo largo de un eje de referencia. Tradicionalmente las imágenes CT capturadas por escáneres de rayos-X, producen un haz de rayos X en múltiples direcciones a través de un corte transversal del objeto para determinar la atenuación de su estructura interna [Figura 1]. Los rayos-X son atenuados en mayor o menor medida en función de la densidad de la estructura, y las atenuaciones son medidas por un detector localizado en el lado opuesto de la fuente [2], como se observa en la figura 1.

Los métodos tradicionales de tomografía computarizada se basan en la estimación de las atenuaciones de los rayos-X, donde una fuente emite un rayo con intensidad I_0 que pasa a través de un objeto. La intensidad del rayo $I(x)$, medida por el detector, depende de la distribución de atenuación $\mu(x)$ en cada punto de su trayectoria, y de

Figura 1. Proceso de adquisición de un escáner de rayos-X.

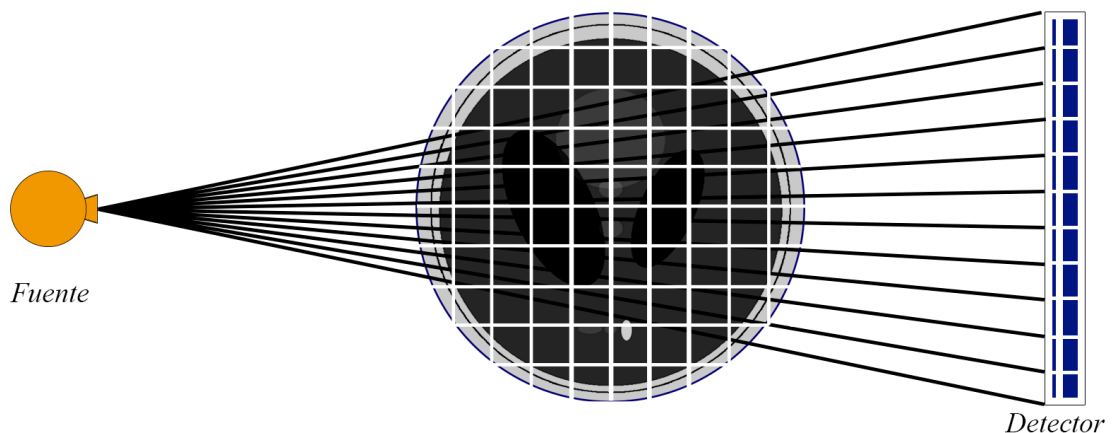



Figura 2. Modelo matemático de la atenuación monocromática de rayos-X. Los fotones se están ejecutando a través de un objeto de espesor Δx con un coeficiente de atenuación constante, μ .




Fuente: [Libro] Thorsten. M. Buzug, 2008.

la distancia x como se muestra en la figura 3. Durante la adquisición de imágenes, el tubo de rayos-X se mueve linealmente en una dirección, mientras que la película de rayos-X se mueve de forma sincronizada en la dirección opuesta. Por esta razón, sólo en los puntos del centro del plano de rotación se crean las imágenes. Todos los puntos por encima y por debajo de esta región son borrosos, y aún más, a mayor distancia desde el centro de rotación [7].

La información borrosa por encima y por debajo del centro de rotación no desaparece, sino que se superpone a la imagen como una capa gris o neblina, provocando una reducción sustancial de contraste.

Figura 3. Representación gráfica de tomógrafo, donde S representa la fuente de rayos-X, O representa el objeto, y $\mu(x)$ representa la densidad del objeto. La matriz de detectores de panel plano D , integra la radiación incidente I_0 e $I(x)$.



La tomografía computarizada evita la súper imposición de cortes borrosos y produce un gran contraste, que permite obtener imágenes de los tejidos blandos, de esta manera las imágenes de CT son usadas exitosamente en diagnóstico médico.

2.1.1. Clasificación de tomógrafos. Históricamente, han surgido cuatro generaciones distintas de CT. Su clasificación se refiere tanto a la forma como se construyen los tubos de rayos-X y los detectores se construyen, y la forma como se mueven alrededor del paciente. El principio del método de tomografía geométrica convencional o analógica se ilustra en la figura 4. Durante la adquisición de imágenes, el tubo de rayos-X se mueve linealmente en una dirección, mientras que la película de rayos-X se mueve de forma sincronizada en la dirección opuesta.


La primera generación, se basa en una geometría de haz de rayos-X paralelos y un único detector. En esta arquitectura la fuente de rayos-X se mueve linealmente a través del objeto en función del ángulo entre la cámara y el isocentro. Este desplazamiento es lineal y se repite para diferentes ángulos de proyección.

Dependiendo de las propiedades de atenuación específica del tejido, la intensidad de los rayos-X se atenúa en su camino a través del cuerpo [Figura 5]. Sin embargo, a partir de una sola proyección no es posible determinar la distribución espacial de los coeficientes de atenuación de los tejidos. Con el fin de determinar la ubicación de los objetos consecutivos en una línea de proyección, la escena debe ser muestreada desde otros puntos de vista. Por lo tanto, el movimiento de traslación-rotación se repite hasta que la fuente de rayos-X y los detectores han rotado 180 grados[2], [7].

En la segunda generación se utiliza un arreglo de alrededor de 30 detectores y un tubo de rayos-X que genera múltiples haces y cada uno incide en un único detector del arreglo. Para esta arquitectura, el procedimiento de adquisición es igual al de la primera, pero con una reducción considerable en el número de rotaciones (de 180 a 6) y por lo tanto, el tiempo de barrido también se reduce notablemente [figura 6]. Sin embargo, ya que el ángulo de apertura del haz en abanico es pequeño, el tubo de rayos-X y el detector deben ser traducidos linealmente antes de que el ángulo de proyección se ajuste para otra proyección [2], [7].

La tercera generación de escáneres de CT tiene un ángulo sustancialmente mayor del abanico de rayos-X y un conjunto de detectores más largo, de tal manera que todo el campo de medición puede ser proyectado simultáneamente por un ángulo de proyección único [Figura 7]. El tiempo de adquisición para los sistemas de tercera

Figura 4. Izquierda: El histórico tomógrafo Grossmann (Lossau 1995; Grossmann 1934). Derecha: El Siregraph T.O.P. de Siemens, equipado con un sistema intensificador de imagen (D), que se mueve sincrónicamente con el tubo de rayos X (R), y por lo tanto define una rebanada (S).



Fuente: [Libro] Thorsten. M. Buzug, 2008.

generación se reduce considerablemente, ya que una rotación puede llevarse a cabo sin interrupción durante el desplazamiento lineal del sistema fuente-detector.

Este tipo de sistemas se convirtió en el más usado actualmente en procesos de diagnóstico médico [2], [7].

Los escáneres de cuarta generación no difieren de los de tercera generación con respecto a la fuente de rayos-X. Al igual que con la tercera generación, la fuente de rayos-X gira continuamente sin ningún desplazamiento lineal. Sin embargo los tomógrafos de cuarta generación se componen de un anillo de detectores fijos (entre 600 y 4800) externo [figura 8 (a)] o interno [Figura 8 (b)], y es el tubo de rayos-X el que gira alrededor del paciente. Esta implementación mejora notoriamente el ajuste de los detectores. Uno de los sistemas usado en la cuarta generación se denomina "abanico inverso", cuyo centro se sitúa en un solo detector [figura 8 (c)]. Un abanico inverso puede ser muy denso, limitado solamente por la velocidad de muestreo de cada detector. A diferencia de los tomógrafos de tercera generación, este escáner no se limita a la resolución espacial de un solo haz en abanico.[2], [7].

Figura 5. Primera generación de tomógrafos. Equipados con un haz de abanico y un único detector. Ambos componentes se mueven linealmente, y la configuración se hace girar a través de diferentes ángulos de proyección, γ . Cada punto dentro del campo de visión debe ser proyectado desde todas direcciones, por lo que la fuente de rayos-X y el detector se hacen girar a lo largo de una trayectoria que cubre 180° .

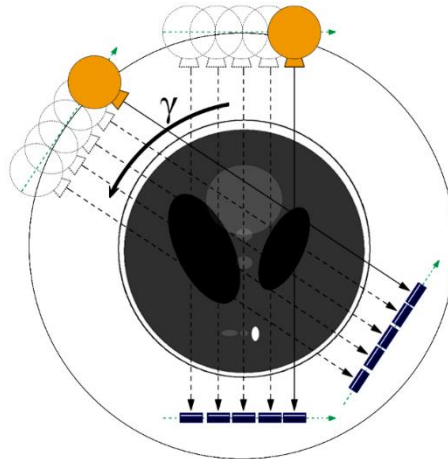


Figura 6. Escáneres de CT de segunda generación. Están compuestos por una fuente de rayos-X con la geometría de haz en abanico, así como un arreglo de detectores corto. El ángulo del abanico es de aproximadamente 10° y el detector se compone de 30 elementos. En este caso, el detector y el tubo también requieren movimiento lineal antes de ajustar el ángulo de proyección.

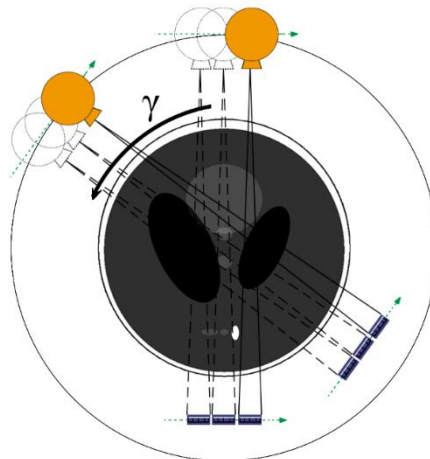


Figura 7. Tercera generación de escáneres CT. Poseen mayor campo de visión (alrededor de 40° a 60°) y un arreglo de detectores más largo (1000 elementos), de tal manera que todo el campo de medición puede ser proyectado simultáneamente por un ángulo de proyección único, γ .


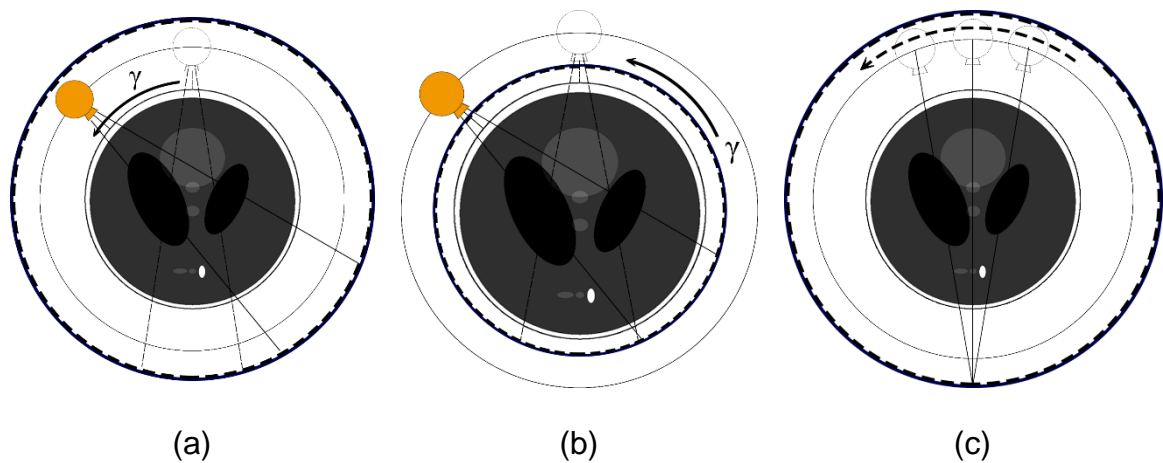


Figura 8. Cuarta generación de escáner CT. **(a)** Escáner de cuarta generación con anillo detector externo. **(b)** Escáner de cuarta generación con anillo detector interno. **(c)** Escáner de cuarta generación con haz de abanico inverso.



2.1.2. Adquisición de datos. Es evidente que el problema fundamental de la tomografía computarizada puede ser fácilmente descrito como la reconstrucción de un objeto desde sus sombras o, más precisamente, a partir de sus proyecciones [2]. Este fenómeno se describe matemáticamente como:

$$I(x) = I_0 e^{-\int_L \mu(x) dx}, \quad (1)$$

donde \int_L representa una integral de línea y L es la trayectoria que recorren los rayos X a través del objeto. La ecuación (1) obedece la ley de Lambert Berr, por lo tanto se puede reescribir como:

$$-\ln\left(\frac{I(x)}{I_0}\right) = -\int_L \mu(x) dx. \quad (2)$$

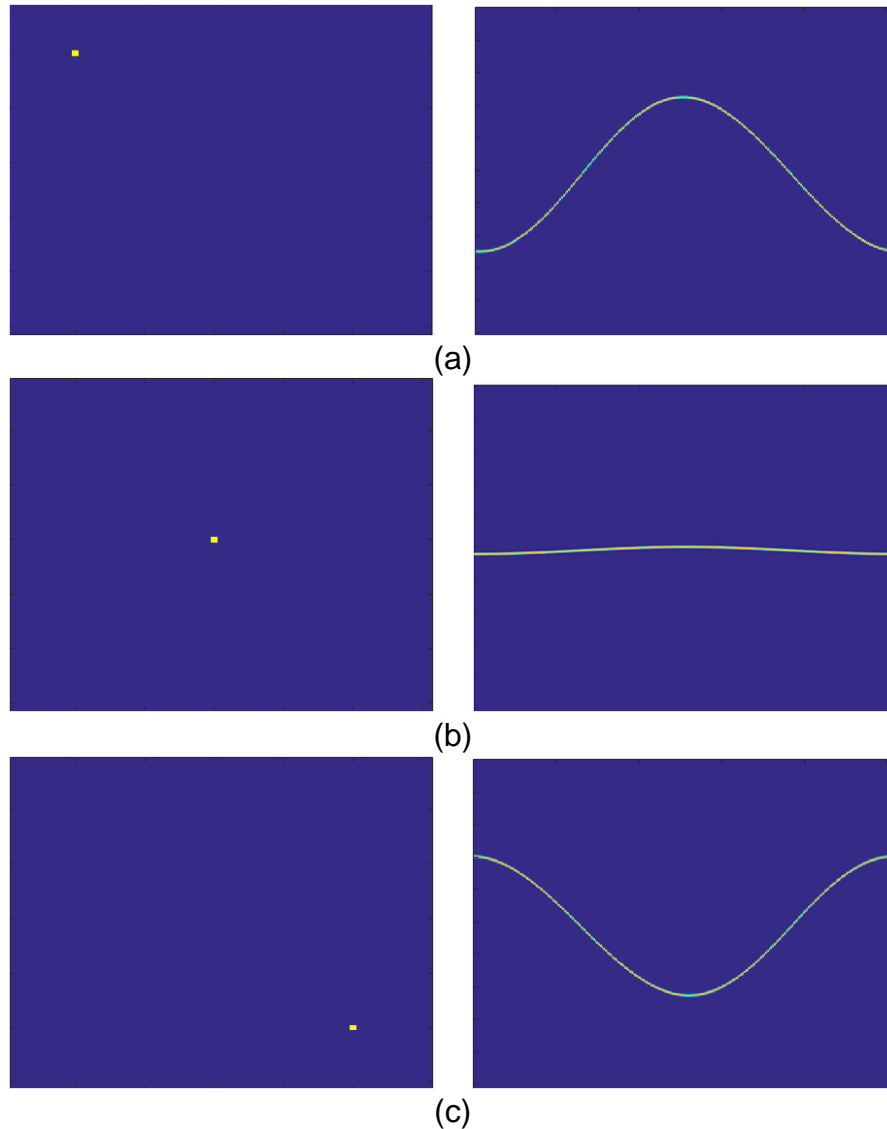
La ecuación (2) se describe cómo la fracción de luz transmitida a través del objeto, y se puede asignar a una proyección unidimensional adquirida con respecto a un ángulo de incidencia. A partir de esa información, la reconstrucción es obtenida mediante la estimación de la distribución de coeficientes de atenuación $\mu(x)$. Las proyecciones que se generan con la estructura de rayos-X, son modeladas mediante la transformada Radón [2]. La transformada Radón representa los datos de proyección obtenidos por un escáner de rayos-X, y su representación 2D es comúnmente conocida como sinograma. Los sinogramas están compuestos por múltiples senoidales, con diferente fase y amplitud, que describen el proceso de transmisión de un rayo a través del objeto, y reciben su nombre debido a la senoidal que se genera al transformar la imagen delta Dirac en el dominio de Radón [Figura 9]. De manera general, para una posición de fuente y ángulo definido, se describe la transformada Radón como:

$$p(s) = \int_0^s \mu(x) dx, \quad (3)$$

donde s representa la longitud de integración, de manera discreta, la ecuación (3) puede ser expresada como:

$$p(s) = \sum_{k=1}^s \mu_k \Delta x. \quad (4)$$

Figura 9. Función Dirac y su representación en el dominio Radón. La imagen de la izquierda representa una función Dirac y la imagen de la derecha su representación en el dominio Radón. Como se puede observar, cada objeto genera una senoidal con una fase y amplitud diferente.



Por otro lado, hay una serie de trayectorias paralelas a través del objeto, que definen un plano de sección o rebanada CT. Por lo tanto, es razonable expresar la proyección integral como una función de la posición lineal de la fuente (o la ubicación del elemento detector correspondiente, ξ) y los ángulos de proyección γ , y no como una función de la trayectoria de s constante entre tubo de rayos-X y el elemento detector. Para este propósito, se define un sistema (ξ, η) , que gira junto con la fuente de rayos X y el detector de coordenadas [Figura 10]. Este sistema de

coordenadas se conoce como el sistema de muestreo de rotación, en contraste con el sistema de coordenadas fijo del paciente (x, y) .

En este caso especial de longitud constante de integración, s , la proyección integral bajo ángulo de proyección γ definida en la rotación (ξ, η) del sistema, se escribe como:

$$p_\gamma(\xi) = \int_0^s \mu(\xi, \eta) d\eta, \quad (5)$$

Basado en la ecuación (5) las mediciones de la intensidad de proyección se pueden organizar en una matriz $\mathbf{I} \in \mathbb{R}^{U \times V}$, que puede ser escrito como:

$$I_{o,p} = \int_{-\Delta\xi}^{\Delta\xi} I_0 e^{p(\xi+\xi',\gamma)} d\xi', \quad (6)$$

donde $o = 0, \dots, U - 1$ es el número de detectores, $p = 0, \dots, V - 1$ es el numero de posiciones del angulo, y $\Delta\xi$ es el ancho del detector. A partir de las ecuaciones (5), y (6), la proyección de datos de atenuación $\mathbf{P} \in \mathbb{R}^{U \times V}$ puede definirse como:

$$P_{i,j} = -\ln\left(\frac{I_{o,p}}{I_0}\right). \quad (7)$$

Tradicionalmente, la reconstrucción de la imagen tomográfica $f(x, y)$ se basa en la proyección de los valores de $P(\xi, \gamma)$. La función de atenuación $f(x, y)$ se puede denotar como una imagen discretizada $\mathbf{F} \in \mathbb{R}^{M \times N}$, o como su representación vectorial $\mathbf{f} \in \mathbb{R}^{MN}$. Donde, $M \times N$ representa las dimensiones espaciales. La discretización de $f(x, y)$ se puede obtener por la integración de todos los valores por encima del píxel cuadrado en las coordenadas espaciales (x, y) . Esto se puede escribir como


$$\mathbf{F}_{i,j} = \int_{-\frac{\Delta s}{2}}^{\frac{\Delta s}{2}} \int_{-\frac{\Delta s}{2}}^{\frac{\Delta s}{2}} f(x_i + x', y_i + y') dx' dy', \quad (8)$$

donde $\Delta s \times \Delta s$ es el área del píxel, (x_i, y_i) son las coordenadas del punto centro del píxel $F_{i,j}$, para $i = 0, \dots, M - 1$, y $j = 0, \dots, N - 1$.

A partir de la definición discretizada de datos de proyección (7), y la imagen reconstruida (8), se plantea el modelo matemático matricial.

$$\mathbf{p} = \mathbf{Ax}, \quad (9)$$

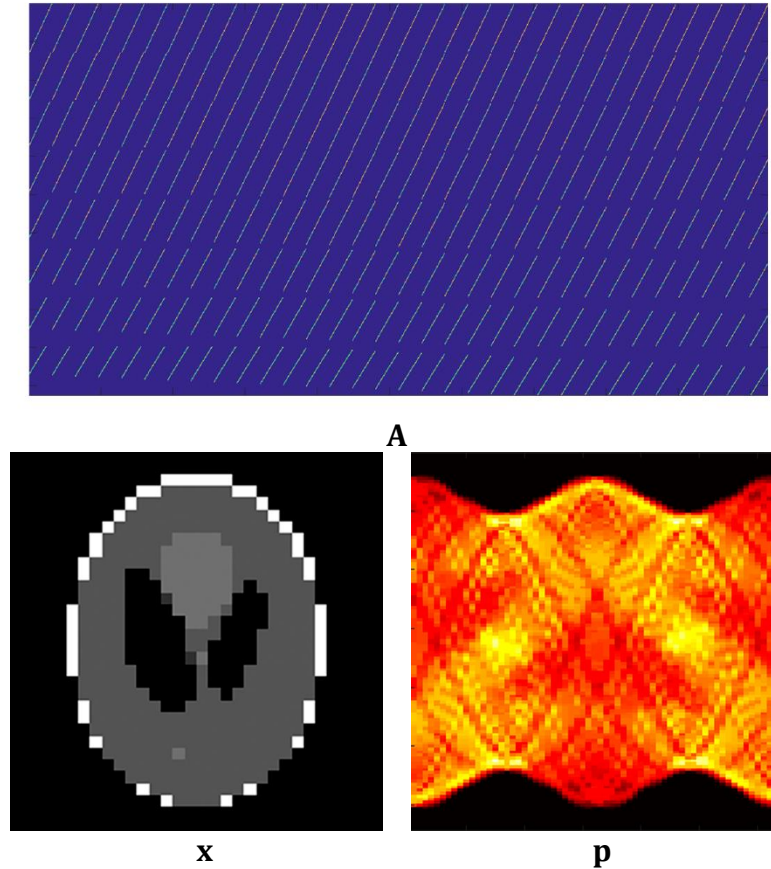
Figura 10. Muestreo espacial de dos dimensiones de un objeto a lo largo de líneas paralelas. La respuesta $P_\gamma(\xi)$, mide la suma de todos los valores de atenuación a lo largo de las líneas de rayos-X en el ángulo de proyección, γ . Cuando la fuente y el detector se desplazan de forma sincronizada tomando proyecciones paralelas para cualquier ángulo γ , los rayos-X paralelos entre sí en el sistema de muestreo giratorio (ξ, η) definen la rebanada que ha de ser reconstruida.



Si la fuente y los detectores se mueven con el mismo radio desde el objeto, la longitud de la integración s es constante. Las mediciones adquisiciones pueden agruparse en un vector $\mathbf{p} \in \mathbb{R}^{U \times V}$, donde U es el número de detectores y V es el número de ángulos, $\mathbf{A} \in \mathbb{R}^{UV \times MN}$ representa la matriz que modela la geometría del sistema y \mathbf{x} contiene todos los valores de atenuación de la región recorrida por el rayo. Las mediciones adquiridas, son usadas para obtener la imagen reconstruida por medio de técnicas como reproyección filtrada [2].

En esta sección, se implementó la librería ASTRA, herramienta que permite simular el proceso de adquisición de un escáner CT. Se simuló una arquitectura fan beam con 32 ángulos, 128 detectores y una resolución de 0.377 mm en cada detector [34]. En la figura 11, se ilustra un ejemplo del modelo matricial de adquisición (ecuación 9), la imagen shepp Logan con dimensiones espacial de 32 x32 pixeles, que representa al objeto muestreado.

Figura 11. Representación matricial del modelo matemático de captura CT, donde \mathbf{A} es la matriz de proyección que contiene la transformada Radon, \mathbf{x} es la imagen original y \mathbf{p} su sinograma respectivo.



2.2. SUPERRESOLUCIÓN

La superresolución (SR, por sus siglas en inglés) es un término utilizado para describir un conjunto de técnicas orientadas al mejoramiento de la calidad de imágenes. El problema de superresolución consiste en recuperar una imagen de alta resolución (HR, por sus siglas en inglés) $\mathbf{x} \in \mathbb{R}^{s_1 M \times s_2 N}$ [Figura 12 (b)] a partir de una versión de baja resolución (LR, por sus siglas en inglés) $\mathbf{y} \in \mathbb{R}^{M \times N}$ [Figura 12 (a)]. Donde $M \times N$ representa las dimensiones espaciales de la imagen y $s_1, s_2 \in \mathbb{R}$ son los factores de superresolución en las dimensiones M y N , respectivamente [21]. Matemáticamente se considera a las imágenes de baja resolución como el resultado del muestreo de una imagen de alta resolución

$$\mathbf{y} = \mathbf{D}\mathbf{H}\mathbf{x} + \boldsymbol{\varepsilon}, \quad (10)$$

donde $\boldsymbol{\varepsilon} \in \mathbb{R}^{MN}$ es un ruido aditivo generado por el sistema, $\mathbf{y} \in \mathbb{R}^{MN}$ y $\mathbf{x} \in \mathbb{R}^{s_1 s_2 MN}$ representan la imagen de LR y HR en orden lexicográfico, respectivamente. $\mathbf{H} \in \mathbb{R}^{s_1 s_2 MN \times s_1 s_2 MN}$ es la matriz de desenfoque y $\mathbf{D} \in \mathbb{R}^{MN \times s_1 s_2 MN}$ es la matriz de sub muestreo. Una aproximación a la ecuación (10) puede ser obtenida mediante la solución del problema inverso dado por:

$$\hat{\mathbf{x}} = (\mathbf{DH})^T(\mathbf{DH}(\mathbf{DH})^T)^{-1}\mathbf{y}. \quad (11)$$

Sin embargo, la ecuación (11) conduce a un sistema indeterminado de ecuaciones lineales que tiene infinitas soluciones en \mathbf{x} , debido a que $MN \ll s_1 s_2 MN$. Una reconstrucción de la imagen puede obtenerse resolviendo el problema de mínimos cuadrados descrito por:


$$\hat{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{DH}\mathbf{x}\|_2^2. \quad (12)$$

Dado que las imágenes obtenidas en la ecuación (12) son de baja resolución espacial, es necesario implementar una función de regularización $F(\mathbf{x})$ para aumentar la calidad de reconstrucción. La ecuación (12) se puede reescribir como:

$$\hat{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{DH}\mathbf{x}\|_2^2 + \gamma F(\mathbf{x}), \quad (13)$$

donde $\gamma \in \mathbb{R}$ es un parámetro de regularización.

Figura 12. Restauración de una imagen de baja resolución por métodos de SR. (a) Imagen de baja resolución, $\mathbf{Y} \in \mathbb{R}^{M \times N}$. (b) Imagen de alta resolución resultante, $\mathbf{X} \in \mathbb{R}^{M s_1 \times N s_2}$, con un factor de superresolución de s_1 y s_2 .



2.2.1. Superresolución por una imagen. Los métodos de superresolución por una sola imagen, se basan en la reconstrucción de imágenes de baja resolución mediante el uso de estructuras locales [Figura 13]. Esta familia de métodos se basa en la hipótesis de que las imágenes están compuestas por la intersección de conjuntos de estructuras locales. Las estructuras locales están formadas por un pixel central y sus pixeles adyacentes; los cuales contienen redundancia de información que permite la restauración de la imagen. Esta familia de métodos es implementada en diversas aplicaciones militares y civiles, ya que no es fácil obtener más de una de imagen de una misma escena.

2.2.2. Superresolución por múltiples imágenes. Los métodos de superresolución por múltiples imágenes se basan en la reconstrucción de imágenes de baja resolución mediante el uso de un conjunto de imágenes de LR [Figura 14]. Estas imágenes de baja resolución tienen desalineación de subpíxeles y se derivan de una misma escena. Esta familia de métodos se basa en la hipótesis de que las imágenes contienen detalles perdidos de alta frecuencia; los cuales son recuperados mediante la implementación de filtros tridimensionales. Los filtros tridimensionales procesan la información contenida en las estructuras locales de las múltiples imágenes de LR (las cuales son adyacentes a la estructura local principal). Sin embargo, en las aplicaciones prácticas no es fácil obtener un número adecuado de imágenes de una misma escena.

Figura 13. Representación esquemática que ilustra el proceso de superresolución con una sola imagen.

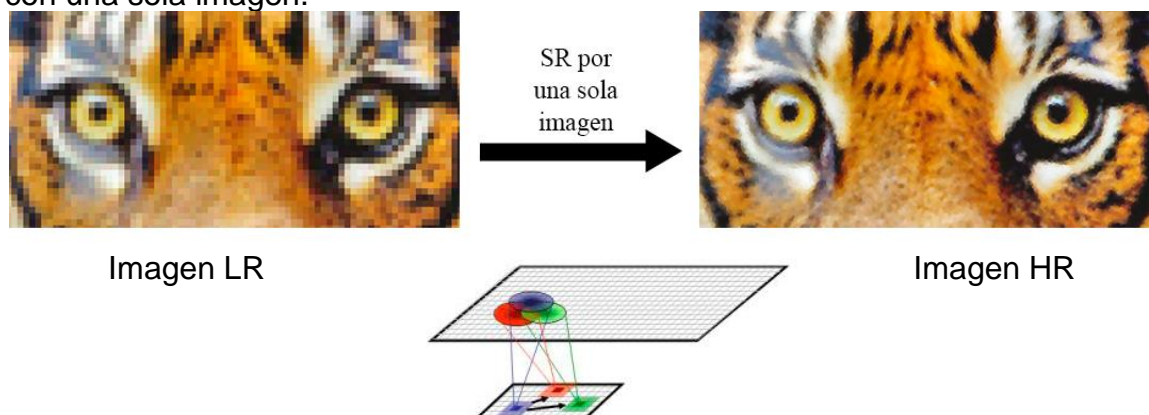
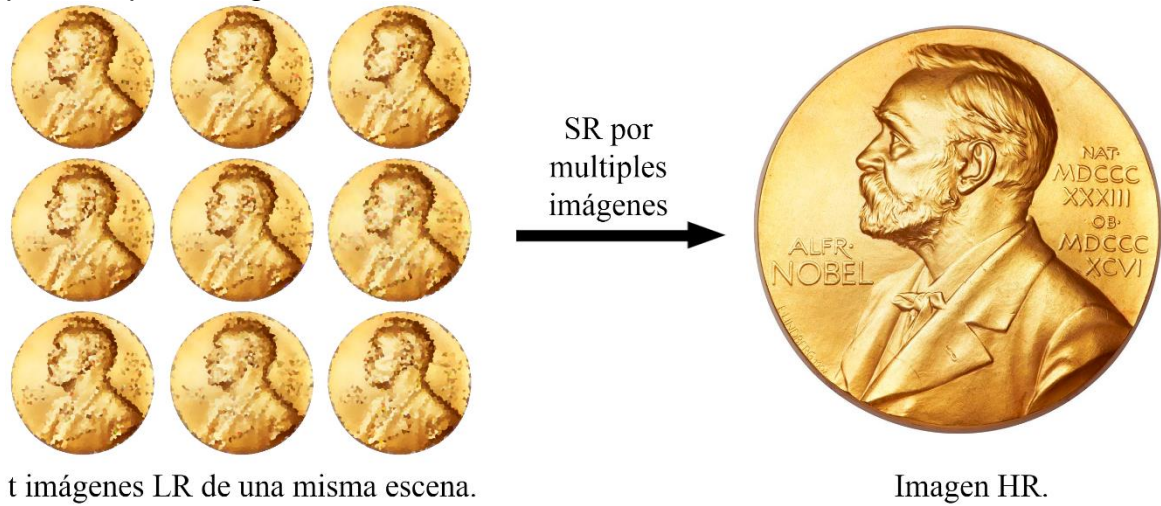


Figura 14: Representación esquemática que ilustra el proceso de superresolución por múltiples imágenes.



$$Y \in \mathbb{R}^{\frac{N}{s_1} \times \frac{M}{s_2} \times t}$$

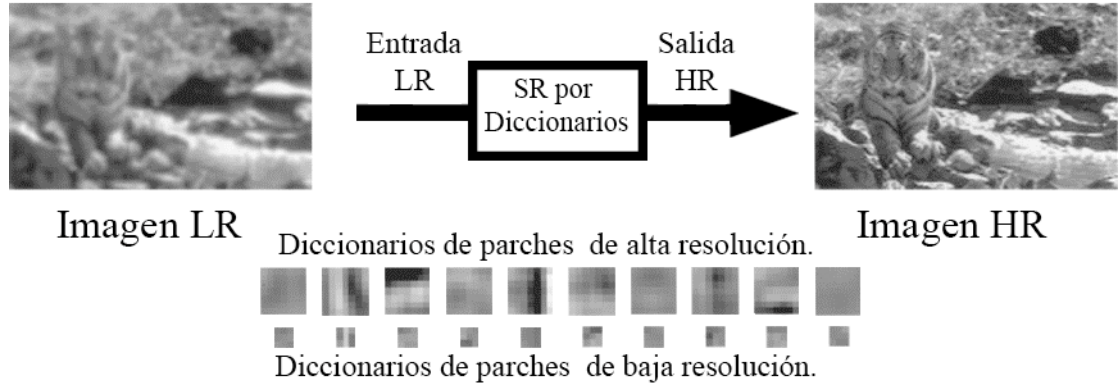
$$\frac{N}{s_1} \ll N \text{ y } \frac{M}{s_2} \ll M$$

$$X \in \mathbb{R}^{N \times M \times 1}$$

2.2.3. Superresolución por entrenamiento de diccionarios. Los métodos de superresolución por aprendizaje de diccionarios se basan en la reconstrucción de imágenes de baja resolución mediante la sustitución de estructuras locales. Esta sustitución se basa en la hipótesis de que para cada estructura local de baja resolución tiene una versión de alta resolución. Las versiones de alta resolución son extraídas de una base de datos de imágenes de HR. A partir de las estructuras de HR extraídas, se generan sus respectivas versiones de LR. El proceso de extracción, creación y almacenamiento de las estructuras locales de HR y LR se conoce como entrenamiento de diccionario. Las estructuras de LR sintéticas son usadas para buscar estructuras similares en la imagen de baja resolución. Seguidamente, las estructuras similares son reemplazadas por su versión de HR contenida en el diccionario.

Una de las desventajas fundamentales de este método, es el entrenamiento de diccionarios para un tipo específico de escena. La implementación de un diccionario no proporciona los mismos resultados en todas las imágenes. Por lo tanto, cada conjunto de escenas similares tiene una base de datos de imágenes de alta resolución. Este proceso es representado en la figura 15.

Figura 15. Representación esquemática del proceso de superresolución por entrenamiento de diccionarios.



2.2.4. Superresolución en imágenes CT. En el enfoque convencional, las imágenes CT de LR se dividen en imágenes bidimensionales de LR y su reconstrucción es considerada como un sub-problema de superresolución de imágenes independientes.

Sea $\theta \in \mathbb{R}^{Ms_1 \times Ns_2 \times Ls_3}$ una imagen CT de alta resolución, y $\lambda \in \mathbb{R}^{M \times N \times L}$ su versión de baja resolución [23], donde M y N representan las coordenadas espaciales y L el desplazamiento a lo largo del objeto.


Las representaciones vectoriales de las imágenes CT de HR y LR están dadas por $\theta \in \mathbb{R}^{Ms_1 \times Ns_2 \times Ls_3}$ y $\lambda \in \mathbb{R}^{M \times N \times L}$, respectivamente, donde L representa el desplazamiento a lo largo del eje de referencia y s_3 su respectivo factor de superresolución. El proceso de adquisición de una imagen CT se modela matemáticamente como

$$\lambda = \mathbf{D}_c \mathbf{H}_c \theta + \xi, \quad (14)$$

donde $\mathbf{D}_c \in \mathbb{R}^{M \times N \times L \times Ms_1 \times Ns_2 \times Ls_3}$ es la matriz de muestreo, $\mathbf{H}_c \in \mathbb{R}^{Ms_1 \times Ns_2 \times Ls_3 \times Ms_1 \times Ns_2 \times Ls_3}$ es la matriz de desenfoque y $\xi \in \mathbb{R}^{M \times N \times L}$ es el ruido gaussiano agregado por el sistema.

Si el objeto a ser reconstruido se compone de muchas estructuras pequeñas, como espumas o hueso trabecular, limitan las posibles mejoras de sobre las técnicas estándares. Por un lado, el efecto de volumen parcial (PVE) rompe el supuesto de que el número de niveles de gris es pequeño. Incluso, objetos binarios ya no pueden ser representados con precisión sobre una cuadrícula con sólo valores de los píxeles negros o blancos [Figura 16]. Además, para objetos pequeños, el número

Figura 16. (a) Un objeto binario. (b)-(d) el mismo objeto binario, representado en una cuadrícula de píxeles con el aumento de tamaño de píxel.



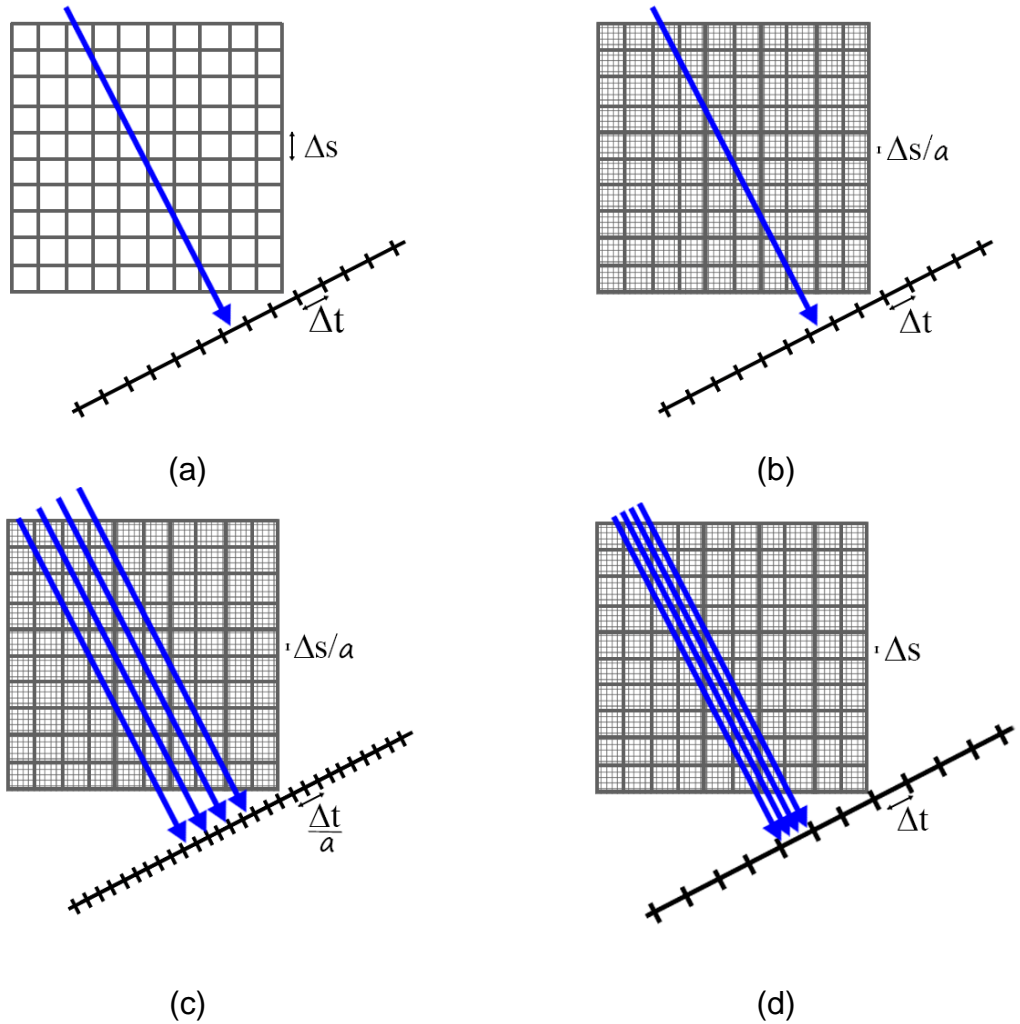
cFuente: [Libro] Thorsten. M. Buzug, 2008.

de elementos será grande, lo que reduce considerablemente el tamaño del problema de reconstrucción [23].

La superresolución de imágenes de tomografía computarizada es descrita claramente en la figura 17, donde se representa en el proceso de captura de los rayos X. En la figura 17 (a), se observa la geometría básica de proyección, donde cada celda del detector de tamaño Δt corresponde a un solo rayo. Para lograr la resolución del detector intrínseco y para contrarrestar la PVE, la red de reconstrucción se sobremuestra [Figura 17(b)]. Sea a el factor de sobremuestreo en cada dimensión. Cada píxel de ancho Δs se subdivide después en a^2 píxeles de $\frac{\Delta s}{a}$ de ancho. Note que $\frac{\Delta s}{a}$, es diferente para Δt , el ancho de la celda del detector. Si los pesos de proyección w_{ij} se calculan por la intersección de un solo rayo con la imagen de muestreo ascendente, algunos píxeles no tendrán un rayo a través de ellos para cada ángulo de proyección y los datos de proyección no serán computados correctamente. En el sinograma de muestreo ascendente [Figura 17 (c)], el número de celdas detectoras se incrementa artificialmente mediante la subdivisión de cada detector de tamaño Δt en unos detectores de tamaño $\frac{\Delta t}{a}$. En el detector de supermuestreo [Figura 17 (d)], el número de rayos virtuales dirigidos a cada celda del detector se incrementa en factor a , donde la resolución de la reconstrucción relativa aumenta por el mismo factor.

Los métodos tradicionales ignoran la información entre capas, que es un parámetro decisivo para obtener una óptima reconstrucción. Por lo tanto se consideran a los métodos tradicionales de superresolución para imágenes de tomografía computarizada como un problema mal planteado.

Figura 17. Superresolución de imágenes de tomografía computarizada (a) Geometría básica. (b) Rejilla de reconstrucción de muestreo ascendente. Se conserva el tamaño del detector y se aumenta la resolución de la imagen. (c) Sinograma de muestreo ascendente. Se aumenta el número de pixeles y detectores. (d) Detector supermuestreo. Se aumenta el número de pixeles y se conserva el tamaño del detector.



3. METODOS TRADICIONALES DE SUPERRESOLUCIÓN

3.1. INTERPOLACIÓN LANCZOS

El remuestreo o filtro Lanczos, es un modelo matemático utilizado para la interpolación de señales o imágenes [35]. Este interpolador es tradicionalmente usado como una técnica de superresolución basada en interpolaciones, que aumentan el tamaño de una imagen LR mediante la implementación de funciones, las cuales se encuentran limitadas por el tamaño del interpolador kernel [Figura 18]. Para obtener una imagen de alta resolución, este método se basa en un interpolador kernel para estimar el pixel de HR.

Matemáticamente se define al filtro de reconstrucción kernel como:

$$L(x) = \begin{cases} \text{sinc}(x)\text{sinc}\left(\frac{x}{a}\right) & \text{si } -a < x < a, \\ 0 & \text{Otros casos} \end{cases}, \quad (15)$$

donde a es un entero positivo, normalmente 2 o 3, que determina el tamaño del kernel y b representa el intervalo de números contenidos en $|a|$.

3.2. SIMILITUD ENTRE VECINOS LOCALES (NON-LOCAL MEANS -NLM)

El filtro NLM es un método de filtrado tradicional en la literatura que se destaca por ser simple y eficaz para la restauración de imágenes con ruido [36]. Éste método asume una estructura local en el conjunto de sus vecinos localizados en diferentes ubicaciones de la imagen figura 19, los cuales son utilizados como múltiples observaciones que permiten la restauración de cada pixel [35], [37]–[40].

La restauración de imágenes por el método NLM se obtiene mediante la sustitución de todos los pixeles por un promedio ponderado de su vecindario. Los pesos son calculados por el promedio de los pixeles que rodean el pixel cuyo valor está siendo determinado.

Matemáticamente, el filtro NLM se formula como una optimización de mínimos cuadrados.

$$\begin{aligned} \hat{z}(x_i) &= \arg \min_{z_i} \sum_{j \in \mathbf{P}(x_i)} [y_j - z(x_i)]^2 w_{ij}^N \\ &= \arg \min_{z_i} (\mathbf{y} - \mathbf{1}z(x_i))^T \mathbf{w}_i (\mathbf{y} - \mathbf{1}z(x_i)), \end{aligned} \quad (16)$$

donde $\mathbf{P}(x_i)$ representa el conjunto de pixeles contenidos en el vecindario de x_i , \mathbf{y} representa la imagen de baja resolución en orden lexicográfico, $\mathbf{1} \in \mathbb{R}$ denota un vector de unos w_{ij} , es la matriz de pesos de los parches locales centrados en la

localización de x_i y x_j , y w_i es una matriz cuyos elementos de la diagonal contiene el promedio ponderado de los pesos del vecindario.

La estimación de mínimos cuadrados de la ecuación 16 es igual al cálculo del pixel objetivo por el promedio de todos los pixeles en su vecindario pertinente $z(x_i)$ al cual está dado por:

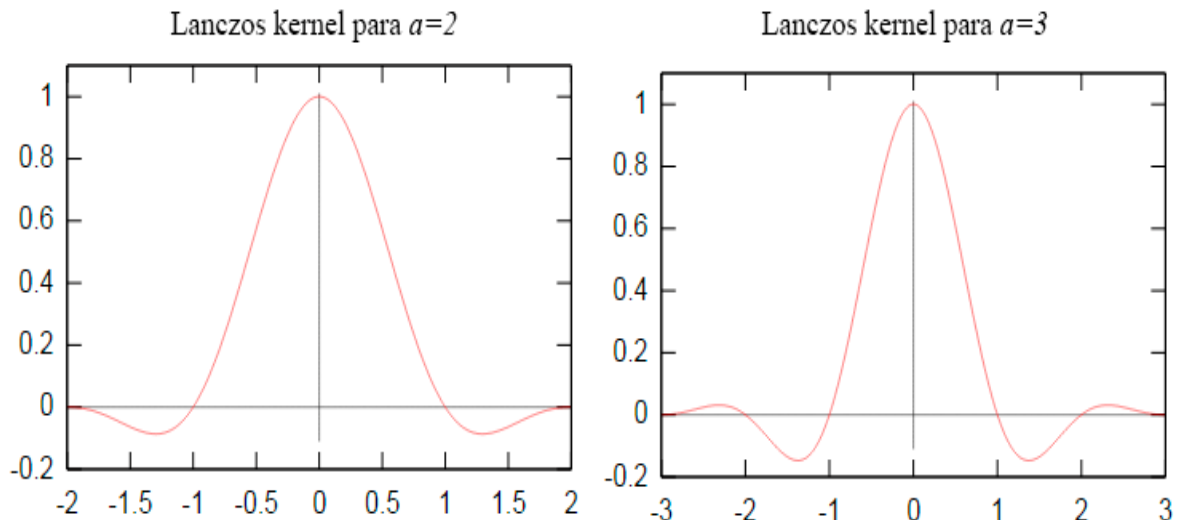
$$z(x_i) = \frac{\sum_{j \in \mathbf{P}(x_i)} w_{ij} y_j}{\sum_{j \in \mathbf{P}(x_i)} w_{ij}}, \quad (17)$$

donde la matriz de pesos w_{ij} es definida como:

$$w_{ij} = \exp\left(-\frac{G \|\mathbf{n}_i - \mathbf{n}_j\|_2^2}{h^2}\right), \quad (18)$$

donde h es un parámetro que controla el decaimiento de la expresión exponencial en el cálculo del peso, \mathbf{n}_i y \mathbf{n}_j representan el vecindario de pixeles contenidos en la localización centrada x_i y x_j en orden lexicográfico, respectivamente. El parámetro G es una matriz kernel que asigna un mayor peso a los pixeles más cercanos al pixel central del vecindario.

Figura 18. Interpolación Lanczos variando el tamaño de su kernel a .



3.3. REGRESIÓN DE NÚCLEO DE DIRECCIONES

Las regresiones de núcleos de direcciones (SKR por su siglas en inglés) son uno de los métodos de filtrado locales más implementados para la reconstrucción de imágenes, ya que muestra un rendimiento eficaz debido a su auto adaptación a la estructura local y robustez al ruido [26], [41]. Este método no-paramétrico se basa en la manipulación de los datos para realizar una aproximación de las estructuras locales. Estas aproximaciones son realizadas por una función regresión [41], que permite modelar la estructura natural de los datos. La implementación de una estructura no-paramétrica tiene, principalmente, tres ventajas sobre las estructura paramétricas.

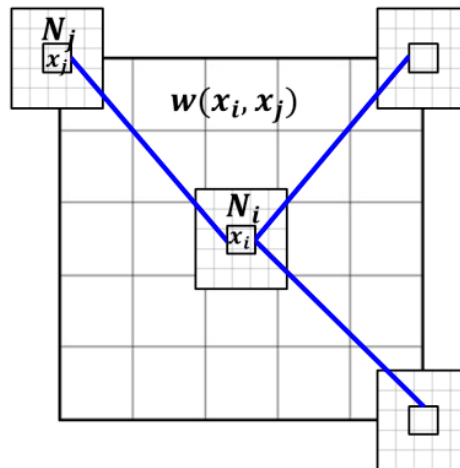
La primera es la adaptación de los problemas como una estimación de características locales de datos, a diferencia de una estructura paramétrica que tiene una implementación más global. La segunda, es que la asignación de pesos por los métodos no-paramétricos no requiere que los datos tengan una estructura de muestreo regular o igualmente espaciada; si las muestras son adyacentes al pixel a restaurar, el marco es válido. En tercer lugar, el enfoque es viable para la eliminación de ruido, e interpolación de datos.

SKR se basa en la estimación de una regresión de pesos de un grupo de pixeles vecinos a un pixel seleccionado. Matemáticamente se representa como:

$$\hat{z}_{i,j} = \underset{x_{i,j}}{\operatorname{argmin}} \sum_{(p,q) \in Q(X_{i,j})} |\hat{X}_{p,q} - \hat{X}_{i,j}|^2 \omega((i,j), (p,q)), \quad (19)$$

donde \hat{X} es la reconstrucción inicial de la imagen de baja resolución, $Q(X_{i,j})$ es el conjunto de posiciones espaciales de todos los vecinos de $X_{i,j}$, y $\omega((i,j), (p,q))$ es el coeficiente de similitud entre los pixeles pertenecientes al vecindario de $\hat{X}_{i,j}$ y $\hat{X}_{p,q}$.

Figura 19. Eliminación del ruido de un pixel mediante el cálculo del promedio de sus pixeles cercanos.

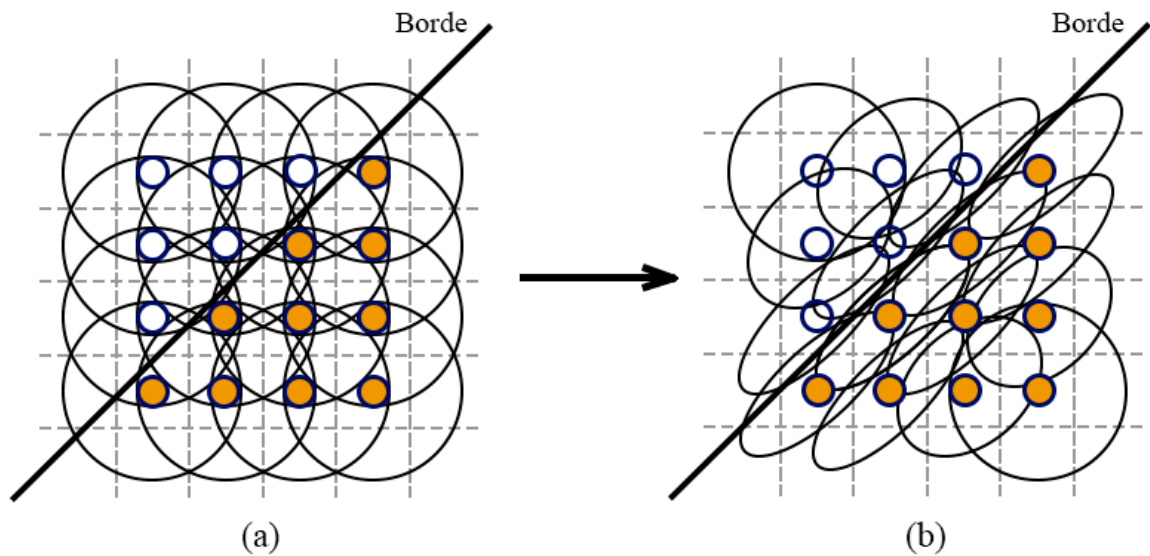


Normalmente, este método toma en consideración el gradiente y analiza la similitud radiométrica de dos píxeles dentro de una ventana local. El coeficiente de direcciones implementado en SKR está definido como:

$$\omega((i, j), (p, q)) = \frac{\sqrt{\det(C_{i,j})}}{2\pi h^2} e^{-\frac{(\hat{x}_{i,j} - \hat{x}_{p,q})^T C_{i,j} (\hat{x}_{i,j} - \hat{x}_{p,q})}{2h^2}}, \quad (20)$$

donde la matriz $C_{i,j}$ contiene el gradiente de covarianza simétrico con respecto al píxel $\hat{x}_{i,j}$, en la dirección vertical-horizontal, y h es un parámetro de suavizado que controla el rango de soporte de la matriz de covarianza. Además $\hat{x}_{i,j}$ y $\hat{x}_{p,q}$ representan el conjunto de píxeles, en orden lexicográfico, contenidos en el vecindario de las posiciones (i, j) y (p, q) , respectivamente. El enfoque SKR permite adaptar las estructuras locales a las características de la imagen [Figura 20 (b)], a diferencia de los métodos tradicionales de filtrado que crean núcleos de vecindarios uniformes [Figura 20 (a)].

Figura 20. Propagación del núcleo en un conjunto de datos muestreados de manera uniforme.



Fuente: [Artículo] Kernel regression for image processing and reconstruction, Figura 8.

4. MÉTODO DE SUPERRESOLUCIÓN PROPUESTO

4.1. PLANTEAMIENTO MATEMÁTICO

En este trabajo se retoma el problema de superresolución para imágenes de tomografía computarizada, proponiendo un enfoque de superresolución espacio-transversal [23], [24]. Para esto se plantea la superresolución propuesta en la ecuación (14), una solución puede encontrarse mediante la ecuación

$$\hat{\theta} = \operatorname{argmin}_{\theta} \|\lambda - \mathbf{D}_c \mathbf{H}_c \theta\|_2^2 + \gamma R(\theta), \quad (21)$$

donde $R(\theta)$ es una función de regularización, $\mathbf{D}_c \in \mathbb{R}^{M \times N \times L \times Ms_1 \times Ns_2 \times Ls_3}$ es la matriz de muestreo, $\mathbf{H}_c \in \mathbb{R}^{Ms_1 \times Ns_2 \times Ls_3 \times Ms_1 \times Ns_2 \times Ls_3}$ es la matriz de desenfoque y $\xi \in \mathbb{R}^{M \times N \times L}$ es el ruido gaussiano agregado por el sistema. Para obtener una óptima reconstrucción, es necesario diseñar un término efectivo de regularización, que está basado en el método SKR. Este proceso se describe matemáticamente como

$$\hat{\theta} = \operatorname{argmin}_{\theta} \|\lambda - \mathbf{D}_c \mathbf{H}_c \theta\|_2^2 + \gamma \|(\mathbf{I} - \mathbf{B})\theta\|_2^2, \quad (22)$$

donde \mathbf{I} es la matriz identidad y

$$\mathbf{B}(i, j) = \begin{cases} \omega((i, j), (p, q)), & \text{si } (p, q) \in Q(X_{i, j}), \\ 0, & \text{otros casos} \end{cases}, \quad (23)$$

representa la matriz de pesos del método SKR. Una solución a la ecuación (23) puede ser obtenida eficazmente usando el método de gradiente descendente, en el cual la t -ésima iteración se expresa matemáticamente como

$$\hat{\theta}^{t+1} = \hat{\theta}^t + \tau (\mathbf{D}_c \mathbf{H}_c)^T (\lambda - \mathbf{D}_c \mathbf{H}_c \hat{\theta}^t) - \alpha (\mathbf{I} - \mathbf{B})^T (\mathbf{I} - \mathbf{B}) \hat{\theta}^t \quad (24)$$

donde τ representa el tamaño de paso para el gradiente descendente y α es el parámetro de regularización para el método SKR.

4.2. ALGORITMO PROPUESTO DE SR PARA CT

En esta sección se presenta el diseño del algoritmo de SR propuesto. El cual contiene una complejidad computacional inferior a la de los métodos de NLM y SKR.

Una descripción detallada del algoritmo propuesto se presenta en la tabla 1. Este algoritmo permite obtener una imagen CT de HR(Θ), en su versión vectorial θ , que satisface las restricciones dadas en la ecuación (20). Además, la imagen de alta resolución está en función de su versión de baja resolución. En resumen, el algoritmo propuesto puede ser descrito en tres pasos. El primer paso es el cálculo

de la imagen inicial de alta resolución utilizando un interpolador cubico Ψ . Este paso permite utilizar la información contenida en los cortes adyacentes y obtener una estimación optima de los cortes faltantes. El segundo paso consiste en calcular la matriz de pesos de SKR, la cual permite reducir el ruido gaussiano de la imagen. Por último, se implementa el método iterativo del gradiente descendente, en el cual se obtienen mejores resultados a partir de reconstrucciones anteriores. La complejidad computacional del algoritmo puede ser reducida al realizar el cálculo de $\tau(\mathbf{D}_c\mathbf{H}_c)^T$ una sola vez antes de iniciar el ciclo iterativo.

Tabla1. Algoritmo de superresolución para imágenes de tomografía computarizada

Objetivo: Estimar una imagen CT de HR CT $(\hat{\Theta}) \in \mathbb{R}^{Ms_1 \times Ns_2 \times Ls_3}$

Entrada:

- Imagen de baja resolución $\Lambda \in \mathbb{R}^{M \times N \times L}$
- Factores de superresolución $s_1, s_2, s_3 \in \mathbb{N}$

Inicialización:

- $t = 0$
- Estimar la imagen de alta resolución inicial, mediante el uso del interpolador cubico

$$\theta^\circ = \Psi\lambda$$

Iteración: Iterar T veces

- Calcular la matriz de pesos de SKR \mathbf{B}
- Actualizar la imagen CT de alta resolución Θ^t , usando la ecuación (16)

$$\hat{\theta}^{t+1} = \hat{\theta}^t + \tau (\mathbf{D}_c\mathbf{H}_c)^T (\lambda - \mathbf{D}_c\mathbf{H}_c\hat{\theta}^t) - \alpha(\mathbf{I} - \mathbf{B})^T (\mathbf{I} - \mathbf{B})\hat{\theta}^t$$

- Actualizar $t = t+1$

Salida: Imagen CT de alta resolución $\hat{\Theta}$

5. SIMULACIONES Y RESULTADOS

Con el fin de evaluar el desempeño del método propuesto, se implementaron tres métodos tradicionales de superresolución en CT: interpolación lineal, interpolación cúbica y reconstrucción por gradiente descendente.

Para simular el proceso de captura de una imagen CT de baja resolución a partir de una imagen de HR, se usaron cinco bancos de imágenes; Tres de los cuales fueron obtenidas del banco de datos Dir lab 4D-CT. Estas imágenes fueron adquiridas con un escáner General Electric Discovery ST PET / CT (GE Medical Systems, Waukesha, WI), figura 21, como parte de la planificación de la radioterapia para el tratamiento de tumores malignos torácicos en la Universidad de Texas [24]. Otro fue cedido al grupo de investigación HDSP, de la Universidad Industrial de Santander, por la radióloga Claudia Córdoba. Y otra fue obtenida de la base de datos sintética de MATLAB®, Shepp-logan. En todas las simulaciones, las imágenes HR tienen 128×128 píxeles y $L = 40$ cortes transversales.

Figura 21. Escáner General Electric Discovery ST PET/CT 600



Fuente: [en línea]: https://capmedplus.com/equipment/ct/ge/ge_discovery_pet_ct_600/

5.1. AJUSTES EXPERIMENTALES

Para simular el proceso de adquisición de una imagen CT de LR, se implementó una matriz de desenfoque gaussiano \mathbf{H} de 5×5 , y una desviación estándar de factor 1. También se implementó una matriz de submuestreo \mathbf{D} , con un factor de reducción $s_1 = s_2 = s_3 = 2$ en las tres dimensiones de las imágenes CT.

Para el cálculo de la matriz de pesos \mathbf{B} del método SKR se usó una ventana de análisis local de tamaño 5×5 , y un parámetro de suavizado $h = 2.5$ para todos los experimentos. Adicionalmente los parámetros $\alpha \in [2, 3.3]$ y $\tau \in [0, 1.5]$ usados en el método iterativo son inicializados en 2.5 y 0.7, respectivamente.

Para realizar las simulaciones, el método de gradiente descendiente y el método propuesto fueron inicializados con un vector de ceros, el interpolador 2D y el interpolador 3D, en busca de mejores resultados de reconstrucción.

5.2. RESULTADOS

Para medir la calidad de reconstrucción del método propuesto, se implementaron tres algoritmos tradicionales de la literatura. La primera métrica es el error cuadrático medio entre la imagen original y la reconstruida (MSE , de su sigla en inglés) y está definido como $MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$, donde \hat{y} es la señal reconstruida e y es la señal original. La segunda métrica es la Relación Pico de Señal a Ruido ($PSNR$, de su sigla en inglés) y está definida como $10 \log_{10} \left(\frac{\max(\hat{y})}{MSE} \right)$, donde $\max(\hat{y})$ es el valor máximo en la imagen [24], [30]. La tercera métrica es la similaridad estructural ($SSIM$, de su sigla en inglés) y está definido como $SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}$, donde μ_x es el promedio de x , μ_y es el promedio de y , σ_x^2 es la varianza de x , σ_y^2 es la varianza de y , σ_{xy} es la covarianza de x y y , $c_1 = (k_1L)^2$, $c_2 = (k_2L)^2$ dos variables para estabilizar la división con el denominador, L el rango dinámico de los valores de píxel, $k_1 = 0.01$ y $k_2 = 0.03$ valores constantes ya establecidos.

En las figuras 22-24, se muestran la imagen original LR, la imagen original HR y las imágenes reconstruidas por los métodos tradicionales y el método propuesto. Para esta representación se utilizan las imágenes CT Caso 3, Cubo y Shepp-Logan Phantom, donde (a) muestra la imagen original LR, (b) muestra la imagen original HR, (c) es la reconstrucción por interpolación 2D (d) es la reconstrucción por interpolación 3D, (e) muestra la reconstrucción utilizando el método del gradiente descendiente y (f) es la reconstrucción utilizando el método propuesto.

Para demostrar la calidad visual de los diferentes métodos, las reconstrucciones de las imágenes Cubo, Caso 3 y Shepp-Logan Phantom, son presentadas en las figuras 25-27, en las cuales se grafica el error absoluto de los cortes transversales,

donde se puede observar que el método propuesto tiene una calidad de reconstrucción superior a los métodos tradicionales, lo cual se puede notar fácilmente en sus bordes. Un análisis exhaustivo de los métodos de reconstrucción son resumidos en la tabla 2, en la cual se puede observar que el método propuesto obtiene mejoras de 1.71 dB – 2.77dB en comparación con el método del gradiente descendente.

La tabla 3 resume los resultados obtenidos al calcular el error relativo entre la imagen original y los métodos de reconstrucción implementados, donde se observa que por medio del método propuesto se obtiene el menor porcentaje de error, con un margen no mayor al 10%.

En las figuras 28-30, se muestran la imagen original, y graficas de los resultados del método propuesto y el método de gradiente descendente, que es el método tradicional con mayor PSNR. En esta figura se visualizan los puntos aleatorios P1-P4, que representan cuatro vectores de atenuación a lo largo del eje x. Para esta representación se utilizan las imágenes CT Caso 3, Cubo y Shepp-Logan Phantom, donde (a) muestra la imagen original con los cuatro puntos seleccionados, (b) presenta la gráfica de la fila en la posición P1, (c) presenta la gráfica de la fila en la posición P2. (d) presenta la gráfica de la fila en la posición P3 y (e) presenta la gráfica de la fila en la posición P4.

Tabla 2. Resultados cuantitativos obtenidos utilizando las métricas tradicionales de la literatura PSNR, MSE y SSIM para los métodos implementados de las imágenes CT.

		Inter 2D	Inter 3D	Gradiente	Propuesto
Caso 1	PSNR	27.3121	30.0107	30.1327	32.2562
	MSE	2×10^{-3}	8×10^{-4}	1×10^{-3}	6×10^{-4}
	SSIM	85.2×10^2	90.1×10^2	89.1×10^2	92.3×10^2
Caso 2	PSNR	31.9867	34.0541	34.2175	36.4159
	MSE	3×10^{-4}	2×10^{-4}	4×10^{-4}	9×10^{-5}
	SSIM	89×10^2	93.1×10^2	92×10^2	94×10^2
Caso 3	PSNR	29.74	33.04	32.58	34.751
	MSE	4×10^{-4}	1×10^{-4}	6×10^{-4}	7×10^{-5}
	SSIM	87.5×10^2	92.3×10^2	91.2×10^2	93.8×10^2
Cubo	PSNR	21.7754	23.08	23.435	25.081
	MSE	6.6×10^{-3}	3.1×10^{-3}	4.5×10^{-3}	3×10^{-3}
	SSIM	74×10^2	79×10^2	73×10^2	80.4×10^2
Phantom	PSNR	22.618	24.208	24.75	26.971
	MSE	5.4×10^{-3}	3×10^{-3}	3.3×10^{-3}	2×10^{-4}
	SSIM	91.3×10^2	92.3×10^2	91.7×10^2	95.9×10^2

Haciendo uso de las imágenes CT Caso 3, Cubo y Shepp-Logan Phantom, en las figuras 31-33, se grafican la imagen original, el método propuesto y el método de gradiente descendente, que es el método tradicional con mayor PSNR. En esta figura se visualizan los puntos aleatorios P1-P4, que representan cuatro vectores de atenuación a lo largo del eje transversal, donde (a) muestra la imagen original con cuatro los puntos P1 a P4, (b) presenta la gráfica del píxel P1, (c) presenta la gráfica del píxel P2, (d) presenta la gráfica del píxel P3 y (e) presenta la gráfica del píxel P1, a lo largo del eje transversal.

Tabla 3. Resultados error relativo entre la imagen Original y los métodos implementados.

	Caso 1	Caso 2	Caso 3	Cubo	Phantom
Original VS Inter 2D	10.4 %	8.1 %	8.4 %	8.0 %	19.5 %
Original VS Inter 3D	8.08 %	6.2 %	6.7 %	7.0 %	16.5 %
Original VS Gradiente	7.7 %	5.9 %	6.5 %	6.5 %	15.9 %
Original VS Propuesto	6.0 %	4.9 %	4.9%	5.8 %	9.7 %

Figura 22. Reconstrucciones imagen CT Caso 3. **(a)** Imagen original LR, **(b)** imagen original HR, **(c)** reconstrucción utilizando interpolación 2D, **(d)** reconstrucción utilizando interpolación 3D, **(e)** reconstrucción por el método del gradiente descendente y **(f)** reconstrucción utilizando el método propuesto.




Figura 23. Reconstrucciones imagen CT Cubo. **(a)** Imagen original LR, **(b)** imagen original HR, **(c)** reconstrucción utilizando interpolación 2D, **(d)** reconstrucción utilizando interpolación 3D, **(e)** reconstrucción por el método del gradiente descendente y **(f)** reconstrucción utilizando el método propuesto.




Figura 24. Reconstrucciones imagen CT Shepp-Logan Phantom. **(a)** Imagen original LR, **(b)** imagen original HR, **(c)** reconstrucción utilizando interpolación 2D, **(d)** reconstrucción utilizando interpolación 3D, **(e)** reconstrucción por el método del gradiente descendente y **(f)** reconstrucción utilizando el método propuesto.






Figura 25. Error absoluto entre las imágenes reconstruidas y la imagen original Caso 3. Donde una mayor intensidad indica un mayor error entre la reconstrucción y la original. **(a)** Imagen original Caso 3. **(b)** Error absoluto de la imagen reconstruida con el método del gradiente. **(c)** Error absoluto de la imagen reconstruida con el método de interpolación 2D. **(d)** Error absoluto de la imagen reconstruida con el método de interpolación 3D. **(e)** Error absoluto de la imagen reconstruida con el método propuesto.



(a)




(b)



(c)



(d)



(e)

Figura 26. Error absoluto entre las imágenes reconstruidas y la imagen original Cubo. Donde una mayor intensidad indica un mayor error entre la reconstrucción y la original. **(a)** Imagen original Cubo. **(b)** Error absoluto de la imagen reconstruida con el método del gradiente. **(c)** Error absoluto de la imagen reconstruida con el método de interpolación 2D. **(d)** Error absoluto de la imagen reconstruida con el método de interpolación 3D. **(e)** Error absoluto de la imagen reconstruida con el método propuesto.




Figura 27. Error absoluto entre las imágenes reconstruidas y la imagen original Shepp-Logan Phantom. Donde una mayor intensidad indica un mayor error entre la reconstrucción y la original. **(a)** Imagen original del cubo sintético. **(b)** Error absoluto de la imagen reconstruida con el método del gradiente. **(c)** Error absoluto de la imagen reconstruida con el método de interpolación 2D. **(d)** Error absoluto de la imagen reconstruida con el método de interpolación 3D. **(e)** Error absoluto de la imagen reconstruida con el método propuesto.




Figura 28. Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje x de la imagen CT Caso 3. Para cada vector se selecciona una posición aleatoria en un corte transversal fijo. El corte transversal es previamente seleccionado aleatoriamente. **(a)** Imagen original con cuatro puntos aleatorios. **(b)** Grafica de la fila P1. **(c)** Grafica de la fila P2. **(d)** Grafica del vector P3. **(e)** Vector P4 graficado a lo largo del eje x.

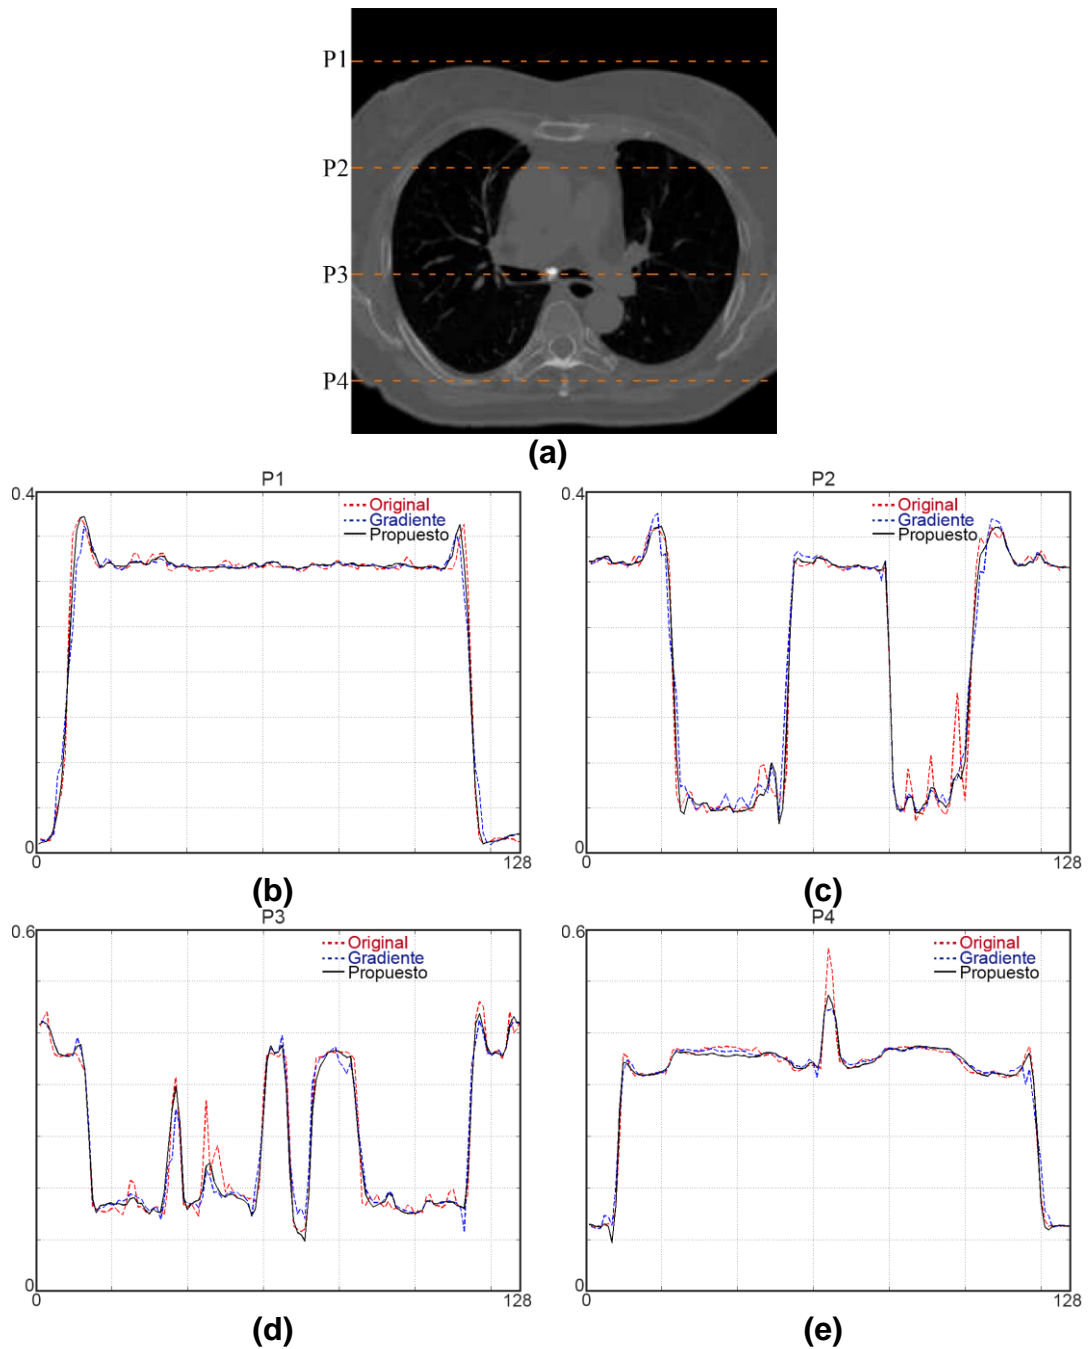


Figura 29. Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje x de la imagen CT Cubo. Para cada vector se selecciona una posición aleatoria en un corte transversal fijo. El corte transversal es previamente seleccionado aleatoriamente. **(a)** Imagen original con cuatro puntos aleatorios. **(b)** Grafica de la fila P1. **(c)** Grafica de la fila P2. **(d)** Grafica del vector P3. **(e)** Vector P4 graficado a lo largo del eje x.

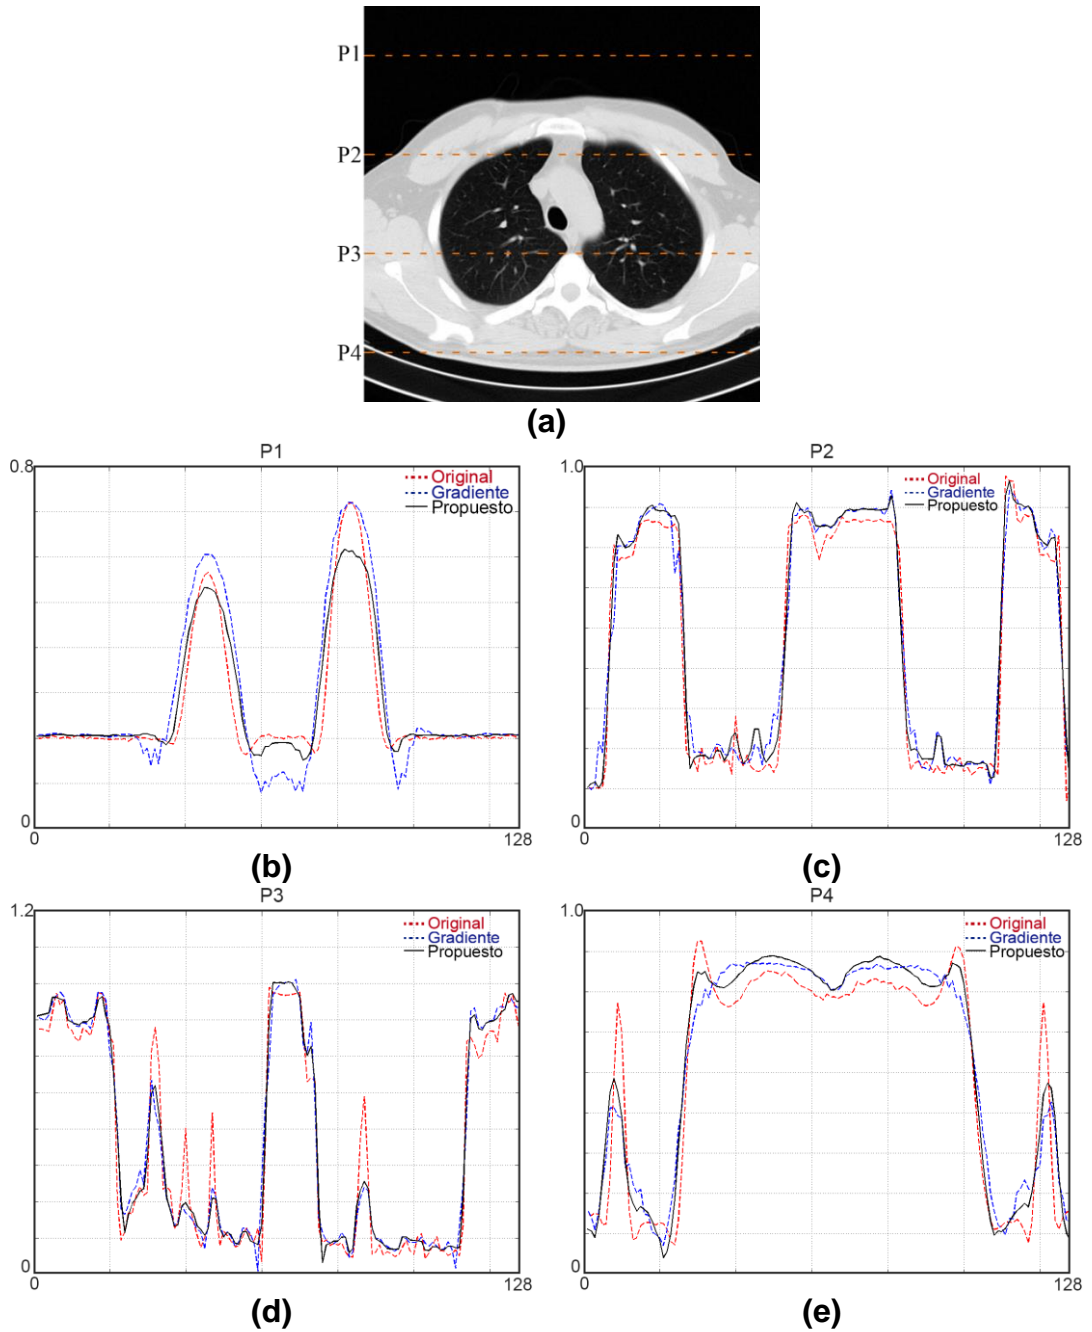


Figura 30. Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje x de la imagen CT Shepp-Logan Phantom. Para cada vector se selecciona una posición aleatoria en un corte transversal fijo. El corte transversal es previamente seleccionado aleatoriamente. **(a)** Imagen original con cuatro puntos aleatorios. **(b)** Grafica de la fila P1. **(c)** Grafica de la fila P2. **(d)** Grafica del vector P3. **(e)** Vector P4 graficado a lo largo del eje x.

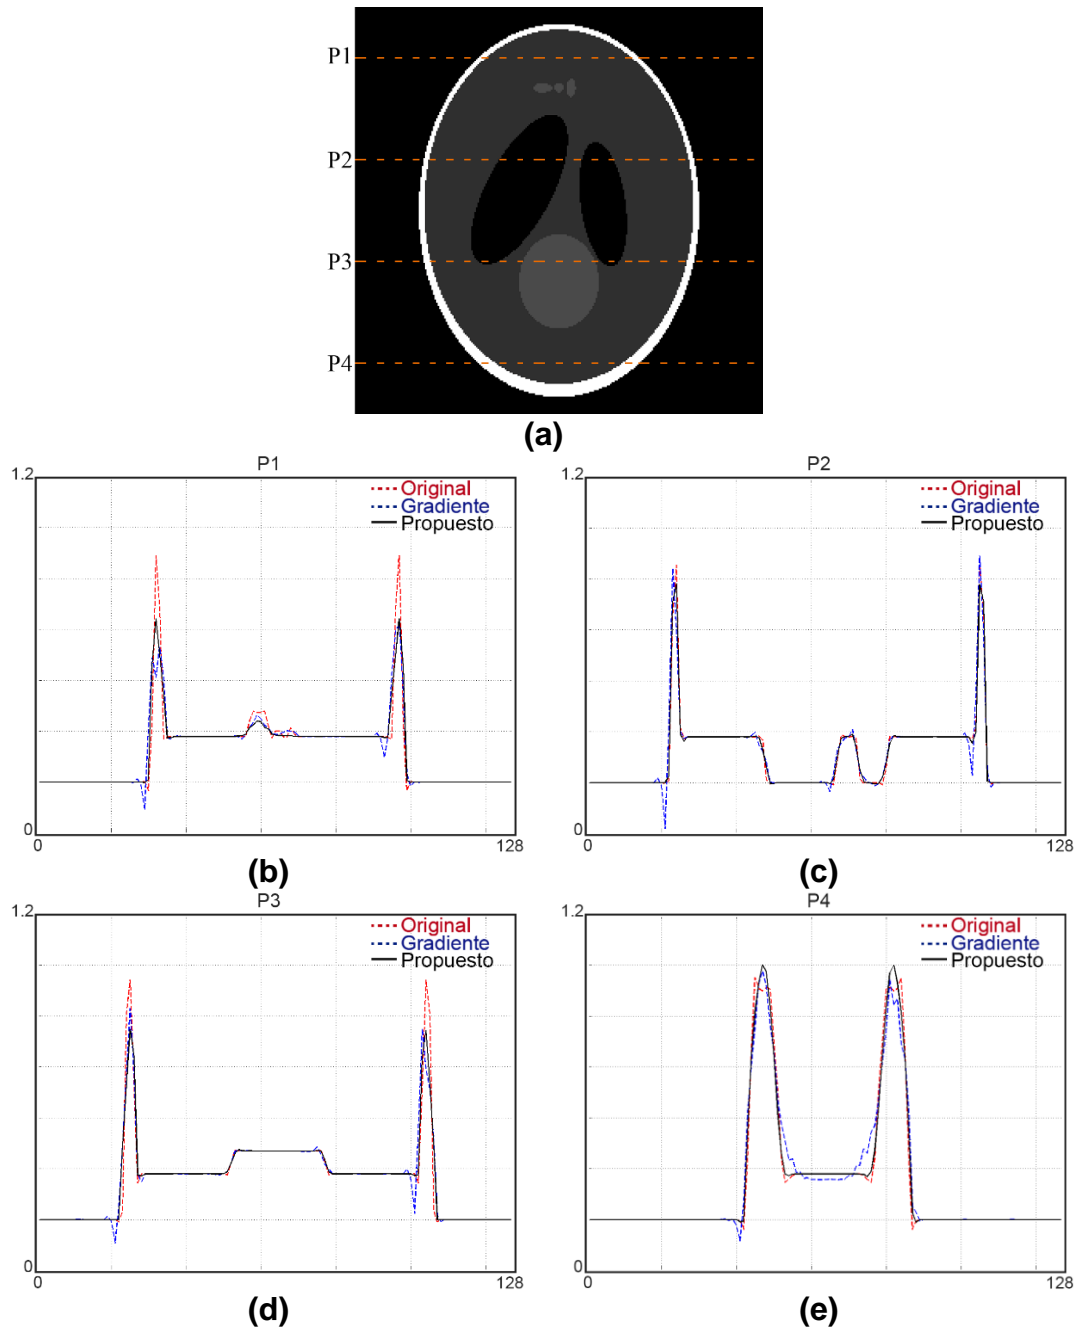


Figura 31. Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje transversal de la imagen CT Caso 3. Para cada vector se seleccionó una posición espacial aleatoria y dicha posición espacial se conserva a lo largo del eje transversal. **(a)** Imagen original con cuatro puntos aleatorios. **(b)** Grafica de la posición espacial P1. **(c)** Posición P2 graficada a lo largo del eje transversal. **(d)** Grafica del vector P3. **(e)** Grafica de la posición espacial P4.

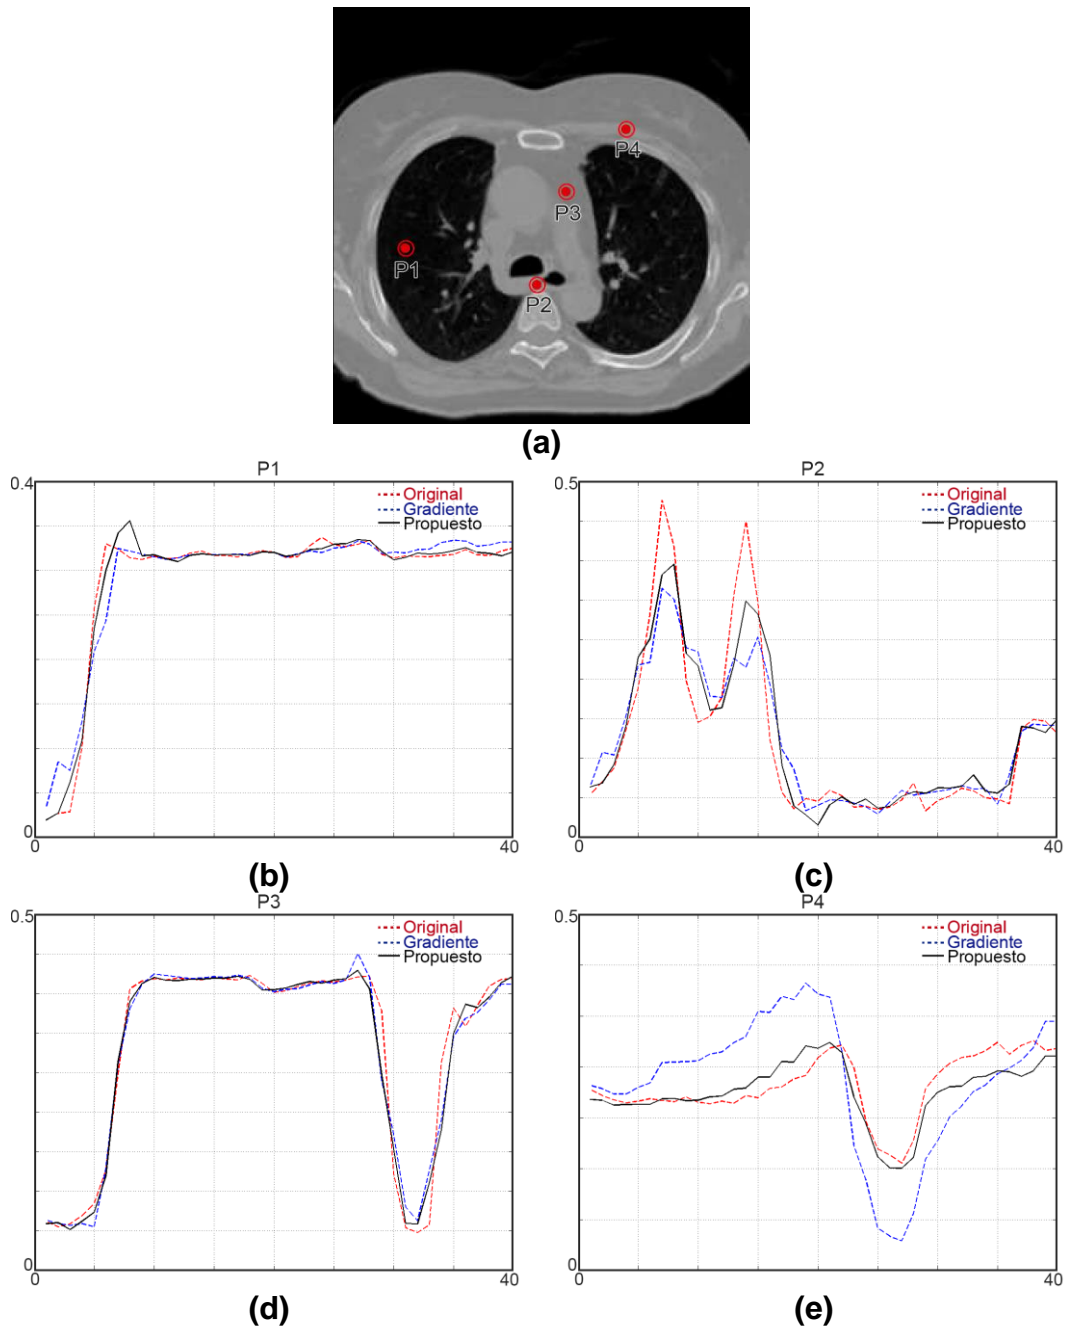


Figura 32. Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje transversal de la imagen CT Cubo. Para cada vector se seleccionó una posición espacial aleatoria y dicha posición espacial se conserva a lo largo del eje transversal. **(a)** Imagen original con cuatro puntos aleatorios. **(b)** Grafica de la posición espacial P1. **(c)** Posición P2 graficada a lo largo del eje transversal. **(d)** Grafica del vector P3. **(e)** Grafica de la posición espacial P4.

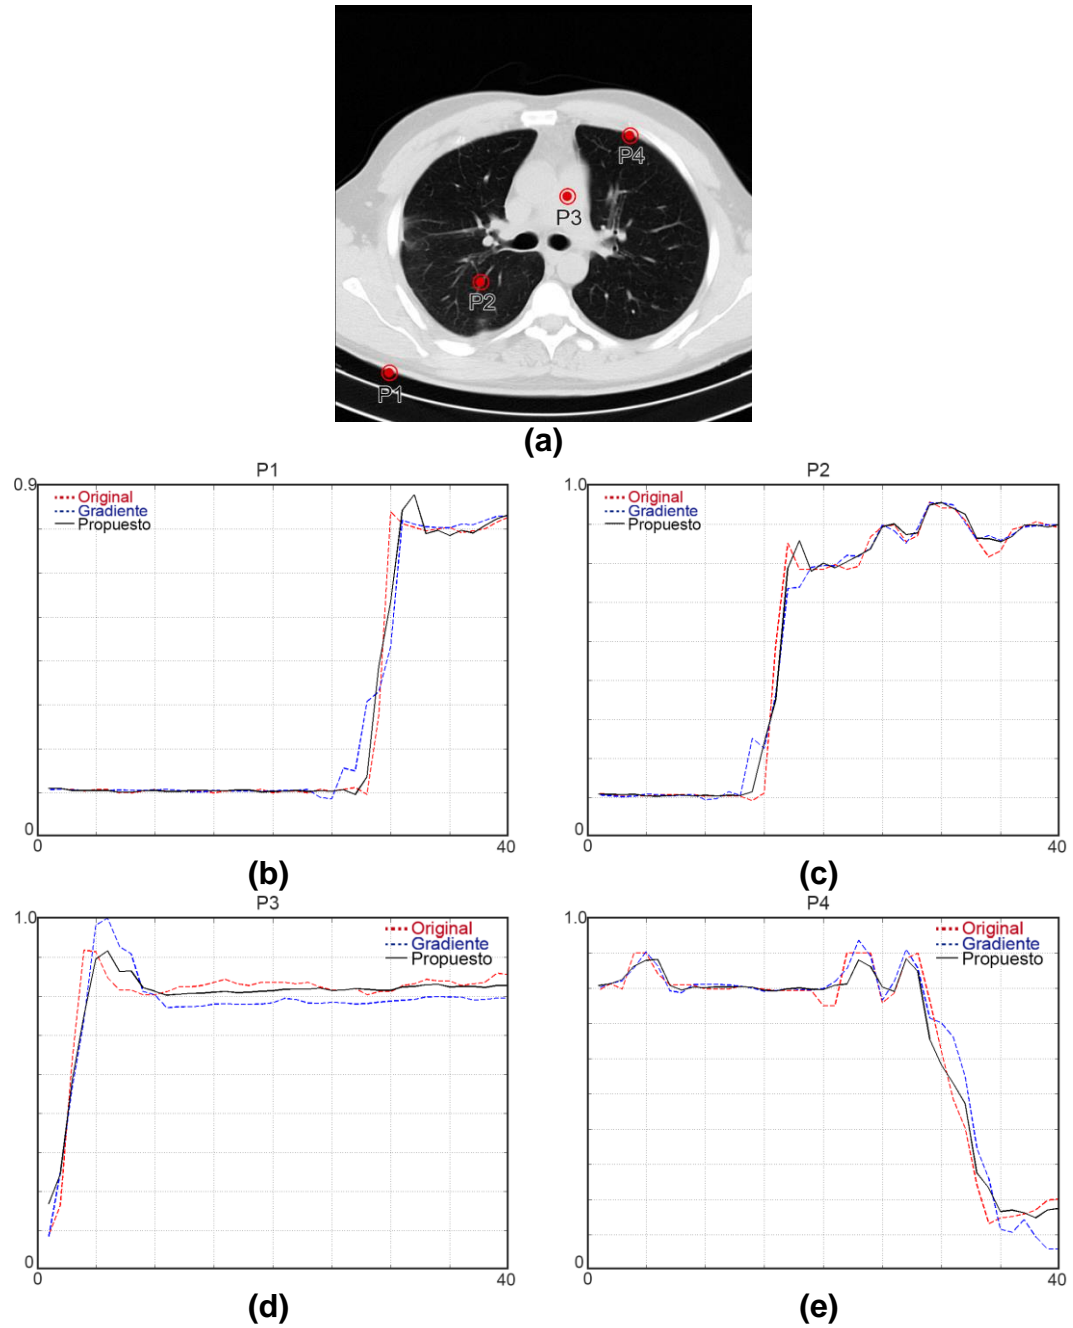
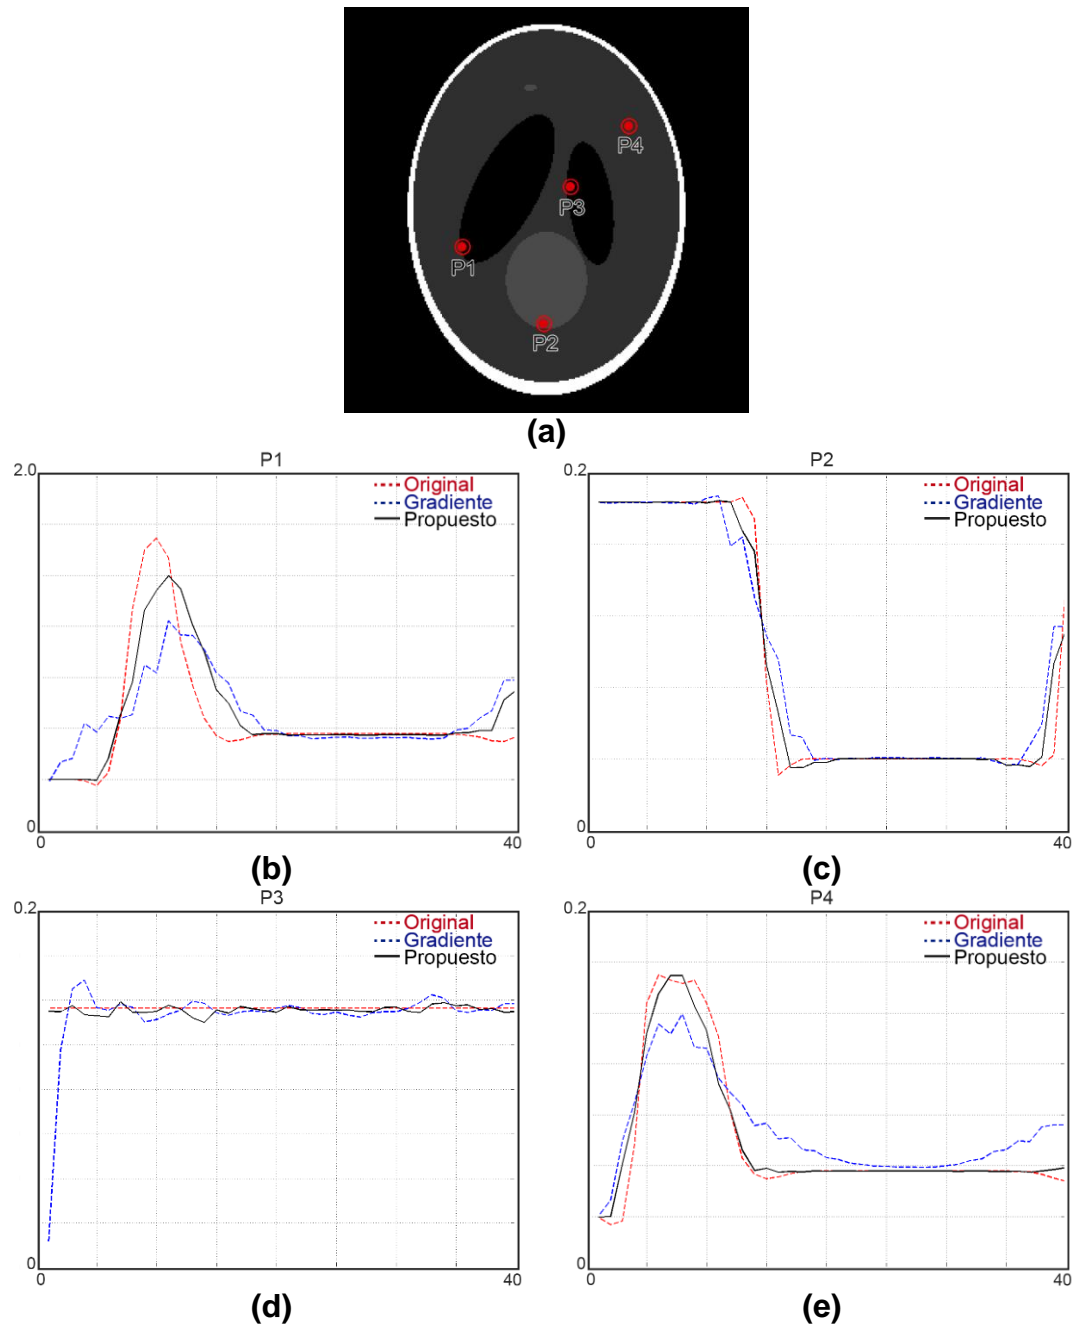


Figura 33. Representación gráfica de la comparación de 4 vectores de atenuación a lo largo del eje transversal de la imagen CT Shepp-Logan Phantom. Para cada vector se seleccionó una posición espacial aleatoria y dicha posición espacial se conserva a lo largo del eje transversal. **(a)** Imagen original con cuatro puntos aleatorios. **(b)** Grafica de la posición espacial P1. **(c)** Posición P2 graficada a lo largo del eje transversal. **(d)** Grafica del vector P3. **(e)** Grafica de la posición espacial P4.



5.3. ANALISIS COMPUTACIONAL

Para comparar el método propuesto en términos de tiempo de CPU, las figuras 34 - 35 muestran los tiempos de cómputo en la reconstrucción de una imagen CT de LR. En la figura 31, se muestran los resultados para cinco secciones de una imagen CT de $[M, N] \in \{(512, 512), (256, 256), (128, 128), (64, 64), (32, 32)\}$ píxeles y $L = 120$ bandas. En la figura 32, se muestran los resultados para cinco secciones de una imagen CT de $[M, N] \in \{(512, 512)\}$ píxeles y $L = \{120, 100, 80, 60, 40, \}$ bandas. En estas figuras se puede observar, que a pesar de que las interpolaciones 2D, 3D y el método de gradiente descendente tienen mejor desempeño en términos de tiempo de CPU, su calidad de reconstrucción es inferior a la del método propuesto. Un análisis más detallado del desempeño de los algoritmos tradicionales y el propuesto, en términos de tiempos de CPU, está resumido en las tablas 4-5. Para el método de gradiente descendente y el propuesto, se usaron 100 iteraciones. Todas las simulaciones fueron realizadas en un computador de características: Intel Core I7 (3.6 GHz), 32 Gb de Ram y tarjeta gráfica NVIDIA Quadro.

Tabla 4. Tiempo de reconstrucción para los métodos tradicionales y el método propuesto, con dimensiones espaciales específicas.

Dimensiones espaciales	Método	Tiempo [s]
512 × 512	Interpolación 2D	86.57×10^{-2}
	Interpolación 3D	13.27×10^{-2}
	Gradiente	7.8391×10^2
	Propuesto	8.9105×10^2
256 × 256	Interpolación 2D	25.70×10^{-2}
	Interpolación 3D	8.11×10^{-2}
	Gradiente	1.8852×10^2
	Propuesto	2.3253×10^2
128 × 128	Interpolación 2D	8.82×10^{-2}
	Interpolación 3D	5.36×10^{-2}
	Gradiente	5.2049×10^1
	Propuesto	5.6721×10^1
64 × 64	Interpolación 2D	4.28×10^{-2}
	Interpolación 3D	4.41×10^{-2}
	Gradiente	1.5447×10^1
	Propuesto	1.5495×10^1
32 × 32	Interpolación 2D	3.25×10^{-2}
	Interpolación 3D	4.26×10^{-2}
	Gradiente	0.3157×10^1
	Propuesto	0.7433×10^1

Tabla 5. Tiempo de reconstrucción para los métodos tradicionales y el método propuesto, con dimensiones transversales específicas.

# de cortes	Método	Tiempo [s]
120	Interpolación 2D	34.87×10^{-2}
	Interpolación 3D	12.09×10^{-2}
	Gradiente	3.6581×10^2
	Propuesto	4.9055×10^2
100	Interpolación 2D	24.89×10^{-2}
	Interpolación 3D	9.61×10^{-2}
	Gradiente	3.1754×10^2
	Propuesto	3.9256×10^2
80	Interpolación 2D	23.75×10^{-2}
	Interpolación 3D	8.90×10^{-2}
	Gradiente	2.6680×10^2
	Propuesto	3.1613×10^2
60	Interpolación 2D	16.91×10^{-2}
	Interpolación 3D	6.98×10^{-2}
	Gradiente	1.8328×10^2
	Propuesto	2.7653×10^2
40	Interpolación 2D	15.31×10^{-2}
	Interpolación 3D	6.77×10^{-2}
	Gradiente	1.5389×10^2
	Propuesto	1.6428×10^2

Figura 34: Representación gráfica del tiempo reconstrucción para los métodos tradicionales y el método propuesto, con dimensiones espaciales 32×32 , 64×64 , 128×128 , 256×256 y 512×512 , correspondientes a la tabla 4.

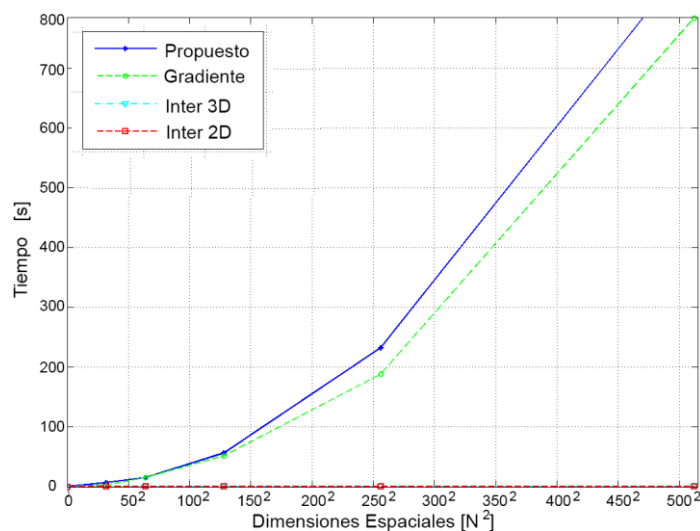
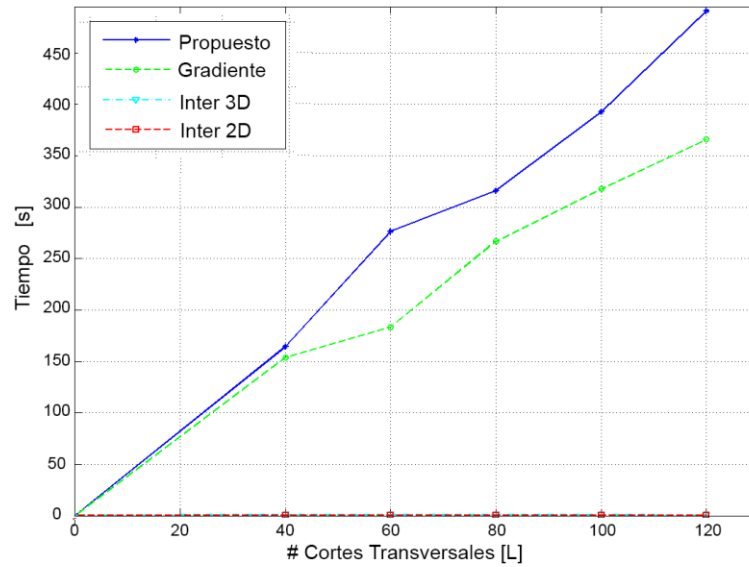


Figura 35: Representación gráfica del tiempo reconstrucción para los métodos tradicionales y el método propuesto, con dimensiones transversales 40, 60, 80, 100 y 120, correspondientes a la tabla 5.



6. CONCLUSIONES

En este trabajo se presentó un método de superresolución para imágenes de tomografía computarizada que aprovecha la información espacio-corte de las imágenes de baja resolución, los resultados de las simulaciones permiten concluir:

- Lo bancos de imágenes de tomografía computarizada son óptimos para realizar el presente y futuros trabajos.
- Se implementaron algoritmos de superresolución tradicionales en la literatura para el mejoramiento de la calidad de imágenes CT.
- Los resultados experimentales muestran que el método propuesto supera los métodos tradicionales basados en interpolación en hasta 2 dB.
- Este método puede ser implementado en arquitecturas tradicionales de tomografía computarizada, sin necesidad de rediseñar la arquitectura del sistema de adquisición.

7. RECOMENDACIONES

- Basándose en el modelo expuesto en el presente trabajo se recomienda, investigar métodos alternativos de superresolución para imágenes de tomografía computarizada.
- Implementar un método de superresolución físico, antes de realizar el proceso de adquisición de las imágenes CT.

CITAS BIBLIOGRAFICAS

- [1] R. De Argandoña, S. Río, and C. J. Llavona, "Aplicación de la tomografía axial computerizada de rayos X al estudio de materiales rocosos," *Univ. Oviedo Serv. Publicaciones.*, pp. 333–338, 1999.
- [2] T. M. Buzug, *Computed Tomography From Photon Statistics to Modern Cone-Beam CT*. 2008.
- [3] C. Madonna, B. Quintal, M. Frehner, B. S. G. Almqvist, N. Tisato, M. Pistone, F. Marone, and E. H. Saenger, "Synchrotron-based X-ray tomographic microscopy for rock physics investigations," *Geophysics*, vol. 78, no. 1, pp. D53–D64, Jan. 2013.
- [4] F. Mees, R. Swennen, M. V. Geet, and P. Jacobs, "Applications of X-ray computed tomography in the geosciences," *Geol. Soc. London, Spec. Publ.*, vol. 215, no. 1, pp. 1–6, Jan. 2003.
- [5] S. Siddiqui, J. Funk, and A. Khamees, "Static and dynamic measurements of reservoir heterogeneities in carbonate reservoirs," *Soc. Core Anal. Int. Symp. Abu Dhabi*, 2000.
- [6] G. L. Raff, M. J. Gallagher, W. W. O'Neill, and J. a. Goldstein, "Diagnostic Accuracy of Noninvasive Coronary Angiography Using 64-Slice Spiral Computed Tomography," *J. Am. Coll. Cardiol.*, vol. 46, no. 3, pp. 552–557, 2005.
- [7] C. Özgen, "Compressed Sensing Based Computerized Tomography Imaging," 2012.
- [8] J. Funk, E. Withjack, and S. Siddiqui, "Core imaging—twenty five years of equipment, techniques, and applications of X-ray computed tomography (CT) for core analysis: Society of Core," ... *Symp. Austin, Texas*, vol. 215, pp. 1–12, 2011.
- [9] F. Khan, "Imaging and modeling of pore scale processes in porous media using X-ray computed tomography and lattice Boltzmann solver," no. March, p. 83, 2014.
- [10] Y. Kuroiwa and S. Hazuki, "Introduction of C/A (covariance/area) with applications to tooth segmentation in dental CT image," in *ICICS 2011 - 8th International Conference on Information, Communications and Signal Processing*, 2011, pp. 5–9.
- [11] W. P. Segars, S. Mendonca, G. Sturgeon, and B. M. W. Tsui, "Enhanced 4D heart model based on high resolution dual source gated cardiac CT images," *2007 IEEE Nucl. Sci. Symp. Conf. Rec.*, vol. 4, pp. 2617–2620, 2007.
- [12] A. Veeraraghavan, A. V. Genkin, S. Vitaladevuni, L. Scheffer, S. Xu, H. Hess, R. Fetter, M. Cantoni, G. Knott, and D. Chklovskii, "Increasing depth resolution

- of electron microscopy of neural circuits using sparse tomographic reconstruction,” *IEEE Int. Conf. Comput. Vis. Pattern Recognit.*, pp. 1767–1774, 2010.
- [13] W.-H. a. Wang and M.-C. L. M.-C. Lin, “A fast method in reconstruction 3D computed tomography medical images,” *Ind. Eng. Eng. Manag. (IE&EM)*, 2010 *IEEE 17Th Int. Conf.*, pp. 1877–1881, 2010.
- [14] C. A. Clavijo and C. H. Mccollough, “Tomografía computarizada por rayos X: fundamentos y actualidad,” *Rev. Ingeniería Biomédica*, vol. 2, no. 4, pp. 54–72, 2008.
- [15] J. L. Prince and J. M. Links, “Medical Imaging Signals and Systems,” Pearson Prentice Hall, 2006, pp. 183–189.
- [16] N. Kothari, Y. K. Bhatshvar, A. Katariya, and S. Kothari, “3D Image Reconstruction Using X-Rays for CT Scan,” *2011 Int. Conf. Comput. Intell. Commun. Networks*, pp. 6–10, Oct. 2011.
- [17] N. R. C. to Assess Health Risks from Exposure to Low Levels of Ionizing Radiation, *Health Risks from Exposure to Low Levels of Ionizing Radiation: BEIR VII Phase 2*. The National Academies Press, 2006.
- [18] P. Perception, E. L. Nickoloff, and P. O. Alderson, “Radiation Exposures to Patients from CT.pdf,” no. August, pp. 285–287, 2001.
- [19] W. Huda, “Radiation Doses and Risks in Chest Computed Tomography Examinations,” *Proc. Am. Thorac. Soc.*, vol. 4, no. 4, pp. 316–320, 2007.
- [20] D. J. Brenner and C. D. Elliston, “Estimated radiation risks potentially associated with full-body CT screening,” *Radiology*, vol. 232, no. 3, pp. 735–738, 2004.
- [21] D. Glasner, S. Bagon, and M. Irani, “Super-resolution from a single image,” *Proc. IEEE Int. Conf. Comput. Vis.*, pp. 349–356, 2009.
- [22] S. C. Park, M. K. Park, and M. G. Kang, “Super-resolution image reconstruction: A technical overview,” *IEEE Signal Process. Mag.*, vol. 20, no. 3, pp. 21–36, 2003.
- [23] W. van Aarle, K. J. Batenburg, G. Van Gompel, E. Van de Casteele, and J. Sijbers, “Super-resolution for computed tomography based on discrete tomography,” *IEEE Trans. Image Process.*, vol. 23, no. 3, pp. 1181–93, 2014.
- [24] Y. Zhang, G. Wu, P. Yap, Q. Feng, J. Lian, W. Chen, and D. Shen, “Reconstruction of Super-Resolution Lung 4D-CT Using Patch-Based Sparse Representation,” pp. 925–931, 2012.
- [25] S. H. A, C. L. Srikanth, and V. Chandrasekaran, “Hybrid Method for Image Super-Resolution Using Steering Kernel Regression and Example-based Approaches,” pp. 288–293, 2013.
- [26] J. Tronicke and U. Boniger, “Steering kernel regression: An adaptive denoising

- tool to process GPR data,” *IWAGPR 2013 - Proc. 2013 7th Int. Work. Adv. Gr. Penetrating Radar*, pp. 1–4, 2013.
- [27] X. Feng and P. Milanfar, “Multiscale principal components analysis for image local orientation estimation,” *Signals, Syst. Comput. 2002. Conf. Rec. Thirty-Sixth Asilomar Conf.*, vol. 1, pp. 478 – 482 vol.1, 2002.
- [28] C. Miravet and F. B. Rodríguez, “A PCA-based super-resolution algorithm for short image sequences,” *Proc. - Int. Conf. Image Process. ICIP*, pp. 2025–2028, 2010.
- [29] K. Zhang, X. Gao, D. Tao, and X. Li, “Single image super-resolution with non-local means and steering kernel regression.,” *IEEE Trans. Image Process.*, vol. 21, no. 11, pp. 4544–56, 2012.
- [30] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, “Image quality assessment: From error visibility to structural similarity,” *IEEE Trans. Image Process.*, vol. 13, no. 4, pp. 600–612, 2004.
- [31] A. Ditter, D. Fey, T. Schon, and S. Oeckl, “On the Way to Big Data Applications in Industrial Computed Tomography,” *2014 IEEE Int. Congr. Big Data*, no. 1, pp. 792–793, Jun. 2014.
- [32] J. L. B. Ribeiro, R. T. Lopes, M. J. Anjos, J. C. Queiroz Neto, L. C. B. Bianco, E. F. Campos, and A. R. D’Almeida, “Study of performance with diverting agents in formation damage and return of permeability for unconsolidated sandstones using computed tomography,” in *IEEE Nuclear Science Symposium Conference Record*, 2007, vol. 2, pp. 1098–1104.
- [33] R. a Zoroofi, Y. Sato, T. Sasama, T. Nishii, N. Sugano, K. Yonenobu, H. Yoshikawa, T. Ochi, and S. Tamura, “Automated segmentation of acetabulum and femoral head from 3-D CT images.,” *IEEE Trans. Inf. Technol. Biomed.*, vol. 7, no. 4, pp. 329–343, 2003.
- [34] D. J. Brady, N. P. Pitsianis, and X. Sun, “Reference structure tomography.,” *J. Opt. Soc. Am. A. Opt. Image Sci. Vis.*, vol. 21, no. 7, pp. 1140–7, Jul. 2004.
- [35] K. Turkowski, “Filters for common resampling tasks,” *Graph. gems*, no. April, pp. 147–165, 1990.
- [36] P. Matan, E. Michael, T. Hiroyuki, and M. Peyman, “Generalizing the Nonlocal-Means to Super-Resolution Reconstruction,” *IEEE Trans. Image Process.*, vol. 18, no. 1, pp. 36–51, 2009.
- [37] C. Tomasi and R. Manduchi, “Bilateral Filtering for Gray and Color Images,” *Int. Conf. Comput. Vis.*, pp. 839–846, 1998.
- [38] a. Buades, B. Coll, and J. M. Morel, “Denoising image sequences does not require motion estimation,” *IEEE Int. Conf. Adv. Video Signal Based Surveill. - Proc. AVSS 2005*, vol. 2005, pp. 70–74, 2005.
- [39] J. Boulanger, C. Kervrann, and P. Bouthemy, “Space-time adaptation for patch-based image sequence restoration,” *IEEE Trans. Pattern Anal. Mach.*

Intell., vol. 29, no. 6, pp. 1096–1102, 2007.

- [40] D. Landgrebe, “Information extraction principles and methods for multispectral and hyperspectral image data,” *Inf. Process. Remote Sens.*, vol. 82, pp. 3–38, 1999.
- [41] H. Takeda, S. Farsiu, and P. Milanfar, “Kernel regression for image processing and reconstruction,” *IEEE Trans. Image Process.*, vol. 16, no. 2, pp. 349–366, 2007.

BIBLIOGRAFIA

- C. A. Clavijo and C. H. Mccollough, "Tomografía computarizada por rayos X : fundamentos y actualidad," *Rev. Ingeniería Biomédica*, vol. 2, no. 4, pp. 54–72, 2008.
- K. Zhang, X. Gao, D. Tao, and X. Li, "Single image super-resolution with non-local means and steering kernel regression.," *IEEE Trans. Image Process.*, vol. 21, no. 11, pp. 4544–56, 2012.
- N. Kothari, Y. K. Bhatshvar, A. Katariya, and S. Kothari, "3D Image Reconstruction Using X-Rays for CT Scan," *2011 Int. Conf. Comput. Intell. Commun. Networks*, pp. 6–10, Oct. 2011.
- S. C. Park, M. K. Park, and M. G. Kang, "Super-resolution image reconstruction: A technical overview," *IEEE Signal Process. Mag.*, vol. 20, no. 3, pp. 21–36, 2003.
- W. P. Segars, S. Mendonca, G. Sturgeon, and B. M. W. Tsui, "Enhanced 4D heart model based on high resolution dual source gated cardiac CT images," *2007 IEEE Nucl. Sci. Symp. Conf. Rec.*, vol. 4, pp. 2617–2620, 2007.
- S. H. A, C. L. Srikanth, and V. Chandrasekaran, "Hybrid Method for Image Super-Resolution Using Steering Kernel Regression and Example-based Approaches," pp. 288–293, 2013.
- T. M. Buzug, *Computed Tomography From Photon Statistics to Modern Cone-Beam CT*. 2008.
- W. van Aarle, K. J. Batenburg, G. Van Gompel, E. Van de Casteele, and J. Sijbers, "Super-resolution for computed tomography based on discrete tomography.," *IEEE Trans. Image Process.*, vol. 23, no. 3, pp. 1181–93, 2014.
- Y. Zhang, G. Wu, P. Yap, Q. Feng, J. Lian, W. Chen, and D. Shen, "Reconstruction of Super-Resolution Lung 4D-CT Using Patch-Based Sparse Representation," pp. 925–931, 2012.