

**UNIVERSIDAD DE CHILE**  
**FACULTAD DE MEDICINA**  
Escuela de Tecnología Médica



## **TESIS PROFESIONAL**

**Para optar al título profesional de Tecnólogo Médico con mención en  
Imagenología, Radioterapia y Física Médica**

**“Uso de sistemas de autosegmentación basados en atlas para  
delimitación de estructuras en planificación de tratamientos en  
radioterapia avanzada”**

**Alumno: Nicolás Andrés Lucero Guerra**

**Tutor: TM MSc. Alexis Ildelfonso Troncoso Vicencio**

Una firma manuscrita en tinta negra, que parece ser la del tutor, escrita sobre una línea horizontal punteada.

**Firma**

**Fecha: 25 de enero de 2023**

## ACTA CURSO TRABAJO DE INVESTIGACIÓN

El **Sr. Nicolás Andrés Lucero Guerra**, estudiante de Tecnología Médica con Mención Imagenología, Radioterapia y Física Médica, cumpliendo con los requisitos establecidos en el plan de estudio, realizó durante el décimo semestre de la carrera, la Tesis Profesional titulada: **“Uso de sistemas de autosegmentación basados en atlas para delimitación de estructuras en planificación de tratamientos en radioterapia avanzada”**, dirigida por el **Prof. Alexis Troncoso**, académico del Departamento de Tecnología Médica, Facultad de Medicina de la Universidad de Chile.

La Escuela de Tecnología Médica designó para su corrección una Comisión integrada por: **Prof. Valeria Zurita**, académica Fundación Arturo López Pérez y el **Prof. Justo Pérez**, académico Fundación Arturo López Pérez.


La calificación obtenida se detalla a continuación:

<b>Corrector 1 Valeria Zurita</b>	6.72	25%
<b>Corrector 2 Justo Pérez</b>	6.66	25%
<b>Tutor(es) Guía:</b>		
<b>Evaluación intermedia</b>	6.00	25%
<b>Nota final tutor</b>	6.00	25%
<b>Nota final tesis profesional</b>	<b>6.35</b>	

En consecuencia el estudiante **Nicolás Andrés Lucero Guerra**, aprueba satisfactoriamente la asignatura.

  
PATRICIO FELIPE  
RIQUELME CONTRERAS  
16.413.786-4  
25/01/2023 - 16:45  
ESTE DOCUMENTO CONTIENE FIRMA ELECTRÓNICA AVANZADA  
<https://itrotopapel.uchile.cl/validacion/verificador>  
CV: 63d186bc942eb377f68597c

**Prof. Patricio Riquelme.**  
Coordinador(a) curso  
Trabajo de Investigación

  
**Prof. Hernán Torres.**  
PEC curso  
Trabajo de Investigación

*A mis padres, Isolda y Moisés, por darme las herramientas que tengo, por siempre darme su apoyo incondicional y hacerme la persona que soy y espero continuar siendo; a mis amigas/os, Aníbal, David, Fernanda, Guillian, Moira, Patricia y Valeria, mi pareja, por siempre estar ahí para desahogarnos, por lo que hemos sufrido juntos a lo largo de este arduo proceso y nunca dejar de tirarnos para adelante.*

*Muchas gracias por su apoyo y su cariño, les quiero mucho.*

## Índice

<b>1. Resumen</b> .....	5
<b>2. Abstract</b> .....	6
<b>3. Introducción</b> .....	7
<b>4. Objetivos</b> .....	9
4.1.    Objetivo general.....	9
4.2.    Objetivos específicos.....	9
<b>5. Metodología</b> .....	10
5.1.    Recolección de información.....	10
<b>6. Revisión Bibliográfica</b> .....	13
6.1.    Aspectos técnicos de los sistemas de autosegmentación.....	13
6.1.1. Registro de imágenes.....	13
6.1.2. Transformación.....	13
6.1.3. Métrica de similaridad.....	14
6.1.4. Optimización.....	17
6.1.5. Multi-atlas.....	17
6.1.6. Fusión de imágenes.....	18
6.2.    Algunos softwares disponibles en el mercado, su funcionamiento, precisión y/o tiempo de delimitación.....	19
6.2.1. ABAS de Elekta.....	19
6.2.2. Precision de Accuray.....	23
6.2.3. SPICE de Philips.....	26
<b>7. Discusión</b> .....	30
<b>8. Conclusiones</b> .....	33
<b>9. Bibliografía</b> .....	35
<b>10. Anexos</b> .....	39

## 1. Resumen

En la última década, se ha desarrollado una herramienta que podría disminuir sustancialmente el tiempo que demora en realizarse el proceso de planificación de tratamientos en radioterapia. La autosegmentación basada en atlas permite la segmentación automática de volúmenes y órganos de riesgo, tomando como referencia uno o más atlas anatómicos de diferentes áreas anatómicas, los cuales han sido aprobados por expertos. Este trabajo busca sistematizar una búsqueda de información respecto al funcionamiento de sistemas de autosegmentación disponibles para planificación en radioterapia, recolectando artículos en las plataformas de Pub Med y la International Journal of Radiation Oncology, Biology, Physics.

Varias compañías han desarrollado sus propios sistemas de autosegmentación, los cuales pueden ser extensiones de sus propios software de planificación de tratamiento, como Precision de Accuray o SPICE de Philips; o puede ser un programa que corre independientemente, como ABAS de Elekta. Cada uno de estos sistemas realiza la delimitación de estructuras de distinta manera, ya sea censando la intensidad de las estructuras en las imágenes o mediante modelos probabilísticos; y deciden de diferente manera la cantidad de atlas a utilizar en la delimitación, pudiendo usar un solo atlas o la fusión de varios atlas distintos.

Estos sistemas pueden realizar delimitaciones consideradas aceptables en un tiempo considerablemente menor que un profesional de manera manual, permitiendo que se agilice el proceso de planificación del tratamiento, pudiendo condensar en unos pocos minutos el trabajo de horas o, incluso, días.

**Palabras clave:** Planificación de tratamiento; autosegmentación basada en atlas; delimitación; órganos de riesgo; software.

## 2. Abstract

In the last decade, a tool has been developed that could substantially decrease the time it takes to complete the treatment planification process in radiotherapy. Atlas-based autosegmentation allows automatic contouring of volumes and organs-at-risk, using one or more anatomic atlases, previously approved by experts, as references for the different structures. This review's objective is to sistematize the search of Information concerning the way that commercialy available autosegmentation systems work, collecting different studies from PubMed and the International Journal of Radiation Oncology, Biology, Physics.

Various companies have developed their own autosegmentation tools, which can be extensions of their own treatment planning systems, like Accuray's Precision or Philips's SPICE; or can be a different software which runs independently, like Elekta's ABAS. Each one of these systems contours volumes in different ways, which can be sensing the intensity of the structures in the images or through probabilistic approaches; and decide differently the amount of atlases that are going to be used for contouring, allowing the use of 1 atlas or the fusion of various other atlases.

This softwares can make contourings that have been deemed acceptable for clinical usage, in a considerably lower span of time tan manual contouring, allowing for an optimization of the time it takes to do the treatment planning process, condensing the work of hours, even days, to just a few minutes.

**Key words:** Treatment planning; atlas based autosegmentation; contouring; organs at risk; software.

### **3. Introducción**

Para la planificación en tratamientos de radioterapia, se requiere la delimitación de volúmenes, tanto de órganos de riesgo como de los respectivos volúmenes de tratamiento (GTV, PTV, etc), con el fin de evaluar la cantidad de dosis que recibirán dichas estructuras una vez planificado el tratamiento, debido a esto, esta delimitación de estructuras debe ser lo más precisa posible, de manera que los órganos de riesgo reciban la menor cantidad de dosis que se pueda. Este contorneo de estructuras se realiza, normalmente, de manera manual, con apoyo de atlas de segmentación, que corresponden a sets de imágenes ya delimitadas de pacientes únicos y previamente aprobados y revisados por médicos radiólogos, oncólogos, etc. Dichos atlas contienen información concerniente a los límites de estructuras, como pueden ser órganos o grupos ganglionares, y/o su relación a distintos hitos anatómicos en distintas regiones de interés [1,2].

El proceso de contorneo manual consume mucho tiempo, ya que se debe ir delimitando corte por corte de la manera más precisa posible, llegando a tomar hasta días de trabajo cuando los cortes del scanner de simulación son muy delgados. Una solución a este problema es el uso de sistemas de autosegmentación, los cuales, como dice su nombre, permiten la segmentación automática de los volúmenes de las estructuras presentes en la región de interés [1,2].

Existen dos tipos de softwares de autosegmentación, basados en atlas y basados en deep learning, aunque estos últimos son más bien escasos, dado que es una tecnología que se está desarrollando en esta área desde hace relativamente poco tiempo. La diferencia entre estos dos tipos de sistemas radica en cómo se le entrega la información al software para 'entrenarlo' y la manera en que realizan la delimitación como tal [1,2,3].

Los sistemas basados en deep learning utilizan redes neurales profundas con múltiples niveles relacionados entre sí, con el fin de determinar las características del set de datos entregado y para establecer las relaciones que existen entre sus partes. Estos algoritmos son ‘entrenados’ mediante el registro de sets de imágenes con sus estructuras ya delimitadas, las cuales el software va a procesar, analizando, abstrayendo y perfeccionando la información a medida que se le ‘entrena’ entregándole más imágenes. Para delimitar las imágenes de un paciente, se utiliza esta base de datos para crear una imagen simulada, la cual será iterada y comparada con la imagen original hasta lograr que sea lo más similar posible a esta [1,3,4].

Por otro lado, la función de los sistemas basados en atlas consiste en deformar no-linealmente las imágenes del atlas hasta que sean similares a la imagen entregada al software, proceso denominado como registro de imagen, que es la aplicación de una transformación a las imágenes del atlas para que se correspondan con las imágenes del paciente [3]. Hay que tener en cuenta un factor importante, y es que, si bien un solo atlas puede que se adapte bien y sea similar a algunos pacientes, también puede que sea muy diferente a otros. Debido a esto, dichos sistemas poseen una recopilación de diferentes atlas (multi-atlas), esto con el fin de cubrir posibles variantes anatómicas que puedan presentar los pacientes. De esta manera, para la delimitación, puede ser utilizado un solo atlas, fusiones de los diferentes atlas o imágenes aisladas de estos que sean más similares a las imágenes del paciente [2,3]. Existen en el mercado varios software de planificación con herramienta de autosegmentación basada en multi-atlas, como ABAS de Elekta, SPICE de Phillips, Precision de Accuray, entre varios otros.



## **4. Objetivos**

### **4.1. Objetivo general**

- Sistematizar una búsqueda de información respecto al funcionamiento de sistemas de autosegmentación disponibles para planificación en radioterapia.

### **4.2. Objetivos específicos**

- Caracterizar aspectos técnicos de los sistemas de autosegmentación, tales como la naturaleza del registro de imágenes; determinación y optimización de la transformación; y uso de multi-atlas.
- Caracterizar sistemas de autosegmentación disponibles en el mercado, su funcionamiento, precisión de estos y/o tiempo que demoran en realizar la delimitación de estructuras

## **5. Metodología**


### **5.1. Recolección de información**

Se realizó la búsqueda de artículos en las bases de datos de las plataformas PubMed e International Journal of Radiation Oncology, Biology, Physics. Fueron recopilados estudios que no tengan más de 10 años desde su publicación, es decir comprendidos entre los años 2010 y 2022. Se consideraron artículos originales publicados en base de datos científicas indexadas, en idioma inglés y español, que fueran realizados en cualquier parte del mundo, cuyo contenido hable respecto al funcionamiento de sistemas de autosegmentación basados en multi-atlas y/o de sistemas de este tipo que estén disponibles en el mercado. Se incluyeron estudios que hablen del método de registro de las imágenes, información respecto a los tipos de deformación que se pueden realizar, métricas de similaridad, optimización, fusión de atlas, tiempo que el software se tarda en realizar la delimitación de estructuras y precisión de la delimitación realizada por estos sistemas. Finalmente, se excluyeron estudios que tengan más de 10 años desde su publicación y estudios que ocupen algoritmos de registro deformable para hacer evaluación dosimétrica. Los criterios están desplegados en la tabla 9.

Al realizar la búsqueda, se obtuvo un total de 104 artículos, de los cuales se excluyeron aquellos con títulos duplicados, quedando 101 artículos. Posteriormente, se procedió a la lectura de los títulos de los artículos, quedando 56 artículos, para luego realizar lectura de los abstract de estos, quedando 24 artículos. Finalmente, estos se leyeron en su totalidad, quedando 17 artículos. Además, se incluyeron otros artículos para complementar la revisión.

<b>Criterios de inclusión</b>	
1. Artículos originales en base de datos científicas indexadas, en idioma inglés y español	
2. Funcionamiento de sistemas de autosegmentación basados en atlas	
3. Sistemas de autosegmentación basados en atlas disponibles en el mercado	
4. Técnica	a. Registro rígido y afín
	b. Registro deformable
	c. Métricas de similitud basadas en geometría
	d. Métricas de similitud basadas en intensidad
	e. Optimización
	f. Fusión de atlas
5. Precisión de la delimitación de diversos sistemas	
6. Tiempo en que dichos sistemas realizan la delimitación	
<b>Criterios de exclusión</b>	
1. Estudios con más de 10 años de antigüedad	
2. Estudios que ocupen algoritmos de registro deformable para realizar evaluación dosimétrica.	

Tabla 9, criterios de inclusión y exclusión.



Esquema 1, diagrama de flujo.

miro

Para la búsqueda en PubMed, se utilizaron los siguientes términos con operadores booleanos:

- (atlas based autosegmentation) AND (radiotherapy)
- (autosegmentation) AND (radiotherapy) AND (registration)
- (autosegmentation) AND (radiotherapy) AND (deformable registration) NOT (dose evaluation)
- (autosegmentation) AND (radiotherapy) AND (similarity)
- (atlas based autosegmentation) AND (planning software)
- (atlas based autosegmentation) AND (label fusion)
- (atlas based autosegmentation) NOT (dose evaluation)

Por otro lado, para la búsqueda en International Journal of Radiation Oncology, Biology, Physics, se utilizaron las siguientes palabras/frases clave:

- Atlas based autosegmentation; radiotherapy image registration; similarity metric; label fusion; autosegmentation software; SPICE Philips; ABAS Elekta; Precision Accuray.

## **6. Revisión Bibliográfica**

### **6.1. Aspectos técnicos de los sistemas de autosegmentación**


#### **6.1.1. Registro de imagen**

Un elemento esencial dentro del funcionamiento de los softwares de autosegmentación, es el registro de la imagen, que corresponde a la determinación de la transformación que se debe aplicar al set de imágenes de la base de datos, con el fin de lograr similitud con el set de imágenes del paciente [1,2,5]. Para esto, se define una imagen fija,  $F$  (imagen del paciente), y una imagen deformable o móvil,  $M$  (atlas). Siendo esta última la que se alterará de acuerdo a un componente transformación espacial  $T$  [6].

#### **6.1.2. Transformación**

$T$  se puede definir como el mapeo de puntos del espacio de  $F$  respecto a puntos correspondientes dentro del espacio de  $M$ .  $T$  puede ser aplicado de dos maneras:

- Global:  $T$  se aplica al volumen completo. Existen dos métodos: transformación rígida, que permite aplicar solamente rotaciones y traslaciones; y transformación afín, la cual permite escalar y torcer el volumen, además de las funciones que ya cumple la transformación rígida [5,6].
- Local:  $T$  se aplica a vóxeles individuales. A esta transformación se le denomina como deformable, no-rígida o no-lineal, y permite el mapeo de tejido blando entre, por ejemplo, 2 adquisiciones de TC distintas del mismo paciente o en adquisiciones de 2 pacientes distintos. La transformación deformable, finalmente, produce una imagen que representa el campo de deformación, donde se muestran los vectores de desplazamiento de cada vóxel individual [5,6]. Esto se puede apreciar en la imagen 1.



*Imagen 1, demostración de la transformación no-lineal obtenida del registro de M, a), en el espacio de F, (b). [5]*

Entonces,  $T(x)$  dicta cómo se alineará y adaptará  $M(x)$  a  $F(x)$ . Pero se necesita una manera de medir qué tan similares son ambos sets de imágenes posterior a la aplicación de  $T(x)$ , por lo que todo esto se debe realizar en concordancia con una métrica de similaridad [2,5,6].

### 6.1.3. Métrica de similaridad

Una métrica de similaridad es, como dice su nombre, un valor que nos permite cuantizar la concordancia entre la imagen fija y la imagen deformable una vez ya aplicada la transformación. Este parámetro es dependiente de varios factores, tales como la morfología de estructuras, diferencias de intensidad, puntos de referencia, etc.

Existen diferentes métodos a partir de los cuales se puede obtener métricas de similaridad.

Los más utilizados son:

#### a. Método basado en geometría

Consiste en establecer una referencia espacial para la selección del atlas a utilizar para la delimitación. Como lo que se requiere es delimitar órganos de riesgo, la referencia a utilizar serían parámetros que permitan comparar la estructura del set de imágenes de la base de datos con la del paciente, asumiendo relaciones entre ambos sets, que pueden ser entre puntos específicos o extensiones de superficie que se correspondan entre sí [2,5,6].

Para determinar la correspondencia entre puntos, se utiliza la ecuación  $R = \frac{\sum(\rho_A - \rho_B)^2}{N}$  como métrica para el registro, donde se calcula la sumatoria de la diferencia cuadrada de las coordenadas de los puntos, dividido por el número total de puntos que se están evaluando. Lo que nos indica este cálculo es, finalmente, que tan distantes están los puntos entre sí. Mientras más cercano a 0 el valor que nos arroje, más cercanos y solapados estarán dichos puntos [5,6].

Por otro lado, la correspondencia entre superficies se realiza tomando una muestra de puntos de la superficie de la estructura del atlas ( $\rho_A$ ) y pedazos de superficie de la imagen del paciente, representadas como una superficie poligonal ( $S_B$ ). Se utiliza la ecuación  $R = \frac{\sum dist(\rho_A, S_B)^2}{N}$ , donde  $dist(\rho_A, S_B)$  es la distancia mínima entre el punto  $\rho_A$  y la superficie  $S_B$ . Esta ecuación para correspondencia de superficies se comporta de la misma manera que la ecuación para correspondencia entre dos puntos [5,6].

#### **b. Método basado en intensidad**

Se basa en evaluar la similitud en la distribución de los vóxeles y los valores que tienen estos en la escala de UH, esto en un ROI que se corresponde entre ambos sets de imágenes, es decir, en el órgano de riesgo. Esta similitud se mide mediante diversas métricas de similaridad, de las cuales, las más usadas son la suma de diferencias cuadradas (Sum of Squared Differences o SSD), correlación cruzada (Cross Correlation o CC) e información mutua (Mutual Information o MI) [5,6]:

- SSD: Se rige bajo la fórmula  $SSD = \frac{\sum(I_A - I_B)^2}{N}$ , donde  $I_A$  e  $I_B$  corresponden a las intensidades de ambas imágenes y N es el número de vóxeles contenidos en el ROI. De la misma manera que la correspondencia entre puntos, este parámetro nos indica que tan distantes están los valores de intensidad entre ambas imágenes. Mientras más cercano a 0 sea el valor que nos entregue esta operación, más similares serán las intensidades de las imágenes.
- CC: Consiste en calcular el producto entre las intensidades de ambas imágenes ( $CC = \sum M(x) * N(x)$ ), asumiendo que existe una relación lineal entre ambas intensidades, permitiendo que las diferencias de brillo y contraste no afecten demasiado al procesamiento de la imagen. Sin embargo, cambios en los valores de vóxel en cualquiera de las imágenes puede aumentar drásticamente el valor de la correlación. Para evitar este problema, la correlación se normaliza (*Correlación cruzada normalizada o NCC*  $= \frac{\sum M(x) * N(x)}{\sqrt{\sum [M(x)]^2 \sum [N(x)]^2}}$ ), pudiendo tomar valores entre -1 y 1. Mientras más cercano a 1 sea el valor, más similares serán las intensidades entre imágenes.
- MI: Tiene gran utilidad cuando los valores de intensidad de los vóxeles de las estructuras correspondientes difieren sustancialmente. Lo que hace es, en esencia, determinar en cada set de imágenes los vóxeles cuyo valor tenga más probabilidad de estar presente dentro de la región de interés, para luego realizar la correspondencia entre imágenes en base a dichos valores de probabilidad.



#### **6.1.4. Optimización**

Lo que se busca, finalmente, es encontrar los parámetros de transformación más eficientes para obtener una imagen cuya métrica de similaridad tenga un valor óptimo, es decir, que sea lo más parecida posible a la del paciente. Por ejemplo, para métricas basadas en geometría se utilizan, por lo general, procesos iterativos, realizando múltiples transformaciones hasta obtener un valor apropiado; o la utilización de modelos probabilísticos para 'predecir' qué transformaciones llevarían a una mayor similaridad [2,5,6].

Dentro de este proceso de optimización, es también importante determinar límites para que las delimitaciones no sean desproporcionadas y poco realistas, lo que se conoce como suavizado [2,5,6].

#### **6.1.5. Multi-atlas**

El uso de un solo atlas puede llevar a imprecisiones en la delimitación de estructuras, debido a posibles variantes anatómicas que podría presentar el paciente. Por esta razón, se ha hecho común la existencia de softwares que poseen 2 o más atlas en su base de datos, es decir, están basados en multi-atlas.

Lo que hacen estos software, es determinar cuál atlas es el más parecido al paciente, para finalmente aplicar el registro deformable. Para esto, a las imágenes de los atlas se les aplica a un registro rígido o afín, con el fin de compensar cualquier rotación o diferencia de posicionamiento que puedan tener con las imágenes de la simulación, se hace una medición de la métrica de similaridad y los atlas serán jerarquizados de mayor a menor de acuerdo a este valor. Finalmente, se le aplicará el registro deformable al atlas más similar o a los  $n$  atlas más similares [5,6].

### **6.1.6. Fusión de imágenes**

Finalmente, tanto para uso de uno o más atlas, se realiza la fusión de imágenes. En el caso de un solo atlas, en cada iteración se fusionan los vóxeles correspondientes entre las imágenes, mientras que, para multi-atlas, se fusionan los atlas elegidos ya deformados y la imagen del paciente. Para decidir qué vóxeles se van a fusionar, se pueden utilizar dos métodos, mediante 'votación' o de acuerdo a métrica de similaridad [5,6].

La 'votación', corresponde a la cantidad de solapamientos que posee un solo vóxel de cada uno de los atlas registrados, entonces, a más votos, más solapamientos. El esquema de votación puede ser hecho de manera probabilística o restringida a una estructura o área particular. Si se hace de manera probabilística, la información fusionada de cada vóxel será medida y comparada, si tenemos un valor de 0, significa que no hubo correspondencia de información en el vóxel, mientras que, si el valor es 1, indica que se corresponde toda la información en ese vóxel. Por otro lado, si hacemos la votación respecto a estructuras particulares, por lo general se realiza ocupando los vóxeles al centro de dicha estructura o aquellos que tengan intensidades similares [5,6].

Si la fusión se hace de acuerdo a métrica de similaridad, se elegirán aquellas imágenes que presentes los valores óptimos de este parámetro, entonces, mediante un proceso iterativo, se retirarán de la fusión las imágenes con valores inapropiados, hasta que se alcance una similaridad que se estime correcta [6].

## **6.2. Algunos softwares disponibles en el mercado, su funcionamiento, precisión y/o tiempo de delimitación**

### **6.2.1. ABAS de Elekta**

ABAS es un motor de autosegmentación desarrollado por la empresa Elekta, el cual no tiene compatibilidad específica con algún equipo, es universal. Tiene la característica de poder crear atlas de manera manual, permitiendo la utilización de sets de imágenes de pacientes previos como atlas, pudiendo así delimitar tanto volúmenes de tratamiento como órganos de riesgo. ABAS, en su versión 1.0, permitía la utilización de un solo atlas para realizar la autosegmentación, sin embargo, en su versión 2.0, se agregó una herramienta llamada Simultaneous Truth and Performance Level Estimation (STAPLE), que permite que el operador determine la cantidad de atlas a usar, delimitando cada atlas por separado para luego fusionarlos, generando una delimitación más precisa que usando un único atlas [7].

La autosegmentación se realiza en dos pasos, primero se realiza un registro deformable, utilizando la correlación cruzada (CC) como métrica de similaridad, y luego se realiza la fusión de imágenes [7]. El sistema cuenta con modelos específicos de diferentes órganos, como la próstata o estructuras de cabeza y cuello, los cuales toman en cuenta características como la elasticidad de las estructuras. Estos modelos son utilizados durante la realización del registro deformable [8].

Se han realizado estudios para determinar la precisión y tiempo de delimitación del software para casos de cáncer de mama y rectoanal [7]; y de cabeza y cuello, pleural y de próstata [8].

En un estudio de Anders, L., et al, del año 2012, se evaluó la precisión de la delimitación de ABAS en sets de imágenes de cáncer de mama y rectoanal. En los casos de cáncer de mama, se utilizaron 3 sets como atlas, con mamas de distinto volumen, pequeñas, medianas y grandes, teniendo como volumen delimitado la mama completa + pared torácica. Estos atlas se utilizaron para delimitar 9 sets de pacientes distintas, primero utilizando los atlas del volumen que se corresponda con cada paciente y luego delimitando todas las pacientes con cada uno de los atlas [7]. Por otro lado, para autosegmentar casos de cáncer rectoanal, se utilizaron 4 sets de imágenes como atlas, 2 de pacientes femeninas y 2 masculinos. Se anotaron los resultados de 1 CTV, que corresponde a grupos de linfonodos iliacos internos, presacros y perirectales. Se delimitó a 12 pacientes en grupos de 6, separados por sexo. Finalmente, se realizó una evaluación utilizando STAPLE, para poder delimitar seleccionando los 3 atlas de cáncer de mama y los 4 atlas de cáncer rectoanal. Los resultados en coeficiente de Sorensen-Dice (CSD), una medida que indica la similitud entre un grupo de datos y otro, se pueden ver en las tablas 1 y 2 [7].

CTV					CTVA				
Atlas/patient		DSC	Logit(DSC)	PO	Atlas/patient		DSC	Logit(DSC)	PO
Small/1-2	Average	0.86	1.82	75.50%	First male/1-6 male	Average	0.82	1.60	70.17%
	SD	0.00	0.00	0.71		SD	0.08	0.50	11.18
Small/1-9	Average	0.86	1.83	75.67%	First male /1-6 female	Average	0.82	1.59	70.67%
	SD	0.02	0.19	3.04		SD	0.6	0.45	8.85
Medium/3-6	Average	0.89	2.12	80.75%	Second male/1-6 male	Average	0.79	1.56	66.33%
	SD	0.01	0.10	1.50		SD	0.09	0.49	11.45
Medium/1-9	Average	0.90	2.19	81.44%	Second male/1-6 female	Average	0.81	1.70	68%
	SD	0.02	0.23	3.36		SD	0.05	0.23	7.35
Large/7-9	Average	0.91	2.36	82.30%	First female/1-6 male	Average	0.82	1.40	69.83%
	SD	0.01	0.07	3.06		SD	0.08	0.52	10.53
Large/1-9	Average	0.87	1.96	76.89%	First female/1-5 female	Average	0.84	1.47	73%
	SD	0.04	0.36	5.47		SD	0.03	0.36	4.3
STAPLE/1-9	Average	0.91	2.27	82.89%	Second female/1-6 male	Average	0.83	1.63	71%
	SD	0.01	0.16	2.09		SD	0.08	0.49	10.45
					Second female/1-5 female	Average	0.83	1.63	70.8%
						SD	0.04	0.28	5.45
					STAPLE/1-12	Average	0.85	1.77	73.67%
						SD	0.06	0.42	8.41

Tablas 1 (izq.) y 2 (der.), resultados en CSD para delimitaciones de cáncer de mamas y rectoanal [7].

Se interpretaron como aceptables aquellos casos en que se obtuviese un CSD > 0,7 y un logit(CSD) > 0,847, este último valor corresponde a la transformación logarítmica del coeficiente de Sorensen-Dice [7].

En los casos de cáncer de mama, no se ve una variación sustancial en los valores obtenidos, sin embargo, cuando se realiza la delimitación usando los volúmenes correspondientes, la precisión tiende a aumentar, pero no es una variación muy grande. Por otro lado, en los casos de cáncer rectoanal, se puede apreciar que hay mayor precisión cuando se ocupan los atlas femeninos, sin mucha variación en la delimitación entre casos masculinos y femeninos. Lo mismo pasa cuando se usan los atlas masculinos, con la diferencia de que tiende a ser ligeramente más precisa cuando se delimitan pacientes femeninas. Para ambos casos, la mejor precisión fue lograda usando STAPLE y fusionando los 3 atlas de mama y los 4 de cáncer rectoanal. Las delimitaciones fueron consideradas aceptables [7].

Otro estudio, realizado por La Macchia, M., et al, en el año 2012, realizó una evaluación de la precisión y el tiempo de la delimitación de casos de cáncer de cabeza y cuello, mesotelioma pleural y cáncer de próstata, realizada por 3 softwares, entre los cuales se encuentra ABAS. Se delimitaron imágenes de 15 pacientes, 5 para cada uno de los casos, evaluando tanto delimitación de OARs como de volúmenes de tratamiento (CTV). Para los casos de mesotelioma, el CTV determinado fue el hemitórax afectado + zona de incisión de toracotomía para drenaje, mientras que para los casos de cáncer de próstata se determinaron 2 CTV, uno que comprende próstata y vesículas seminales (CTV1) y uno que corresponde al lecho tumoral y linfonodos pélvicos (CTV2). No se especificó la correspondencia de los CTVs de cabeza y cuello [8].

Se midió el coeficiente de Sorensen-Dice, antes y después de realizar correcciones manuales a la autosegmentación del software. Los resultados se muestran en las tablas 3, 4 y 5 [8].

El tiempo que el sistema demoró en realizar la delimitación fue de 10' 58" para cáncer de cabeza y cuello, 8' 32' para mesotelioma pleural y 14' 51" para cáncer de próstata [8].

Estructura	CSD	CSD corregido	Estructura	CSD	CSD corregido
CTV1	0,68	0,72	Mandíbula	0,89	0,9
CTV2	0,84	0,85	Médula espinal	0,7	0,84
Laringe	0,86	0,9	Glándula parótida der.	0,78	0,8
Faringe superior	0,36	0,57	Glándula parótida izq.	0,79	0,8
Faringe media	0,57	0,61	Cóclea der.	0,63	0,8
Faringe inferior	0,65	0,71	Cóclea izq.	0,69	0,78
Tiroides	0,73	0,81	Tronco encefálico	0,8	0,88
Espacio masticador der.	0,8	0,85	Esófago	0,63	0,83
Espacio masticador izq.	0,79	0,86			

Estructura	CSD	CSD corregido
CTV1	0,86	0,88
CTV2	0,77	0,87
Recto	0,77	0,9
Vejiga	0,93	0,95
Intestino	0,83	0,89
Cabeza femoral der.	0,94	0,94
Cabeza femoral izq.	0,94	0,94

Estructura	CSD	CSD corregido
CTV	0,85	0,85
Pulmón contralateral	0,95	0,97
Esófago	0,68	0,69
Corazón	0,88	0,9
Intestino	0,77	0,87
Hígado	0,93	0,93
Riñón izq.	0,89	0,91
Riñón der.	0,89	0,91
Médula espinal	0,71	0,73
Bazo	0,92	0,93

*Tablas 3 (arriba), 4 (abajo izq.) y 5 (abajo der.), resultados en CSD para delimitaciones de cáncer de cabeza y cuello, cáncer de próstata y mesotelioma pleural, respectivamente, antes y después de realizar correcciones manuales [8].*

Para las delimitaciones no corregidas, se obtuvo un valor promedio de CSD de 0,717 para los casos de cáncer de cabeza y cuello, de 0,847 para casos de mesotelioma pleural y de 0,8628 para casos de cáncer de próstata.

Llama la atención la sustancial diferencia en los valores de CSD entre los contornos corregidos y no corregidos de los casos de cabeza y cuello.

### 6.2.2. Precision de Accuray

El software de planificación Precision, de Accuray, posee una herramienta de autosegmentación basada en multi-atlas, la cual puede ser utilizada para tratamientos de cerebro, cabeza y cuello y pelvis masculina. Para la delimitación de cerebro, el software Precision dispone de 20 atlas basados en imágenes de Resonancia Magnética potenciadas en T1, con 139 regiones anatómicas cerebrales delimitadas. Mientras que, para cuello y cabeza, se dispone de 36 atlas basados en imágenes de Tomografía Computada. No hay información respecto a la cantidad de atlas disponibles para la autosegmentación de pelvis masculina, sin embargo, se sabe que están basados en imágenes de Tomografía Computada [9,10]. Este software es compatible con los equipos Radixact y Cyberknife de Accuray, para tratamientos de tomoterapia y radiocirugía estereotáctica, respectivamente. Tanto el software como los equipos están disponibles en la Fundación Arturo López Pérez (FALP).

Precision aplica un método de registro basado en intensidad, utilizando la NCC como métrica de similitud [11]. La medición se realiza comparando pequeños parches que se corresponden entre imágenes, por lo que la eficiencia de la delimitación no se verá muy afectada si los valores de intensidad de las estructuras en las imágenes del paciente difieren mucho de los valores de los atlas de los cuales dispone el sistema, ya sea por falta de homogeneidad de la estructura o artefactos [6]. La similitud es optimizada mediante iteraciones sobre todo el campo de la imagen, con un esquema de multi-resolución de grueso a fino, es decir, la imagen se submuestra para obtener una imagen de resolución 'gruesa', para luego aumentar gradualmente la resolución en cada nivel de resolución, realizando 500 iteraciones por nivel, utilizando normalmente 3 o 4 [11].

El software también permite seleccionar niveles de suavizado de la deformación, bajo, medio y alto, siendo el suavizado medio el que se recomienda utilizar y está seleccionado por defecto. El suavizado bajo se utiliza cuando se requiere una gran deformación, ya que permite mayor flexibilidad del campo de deformación, mientras que el suavizado alto disminuye la flexibilidad de la deformación y la hace más rígida, por lo que se recomienda su uso cuando las imágenes del paciente tienen una baja CNR y/o baja resolución espacial [11].

El algoritmo del software selecciona y deforma los atlas morfológicamente más similares, para luego fusionarlos después de valorarlos de acuerdo a un esquema de votación, para consensuar la autosegmentación final [11].

La misma empresa desarrolladora, Accuray, evaluó la precisión de la autosegmentación del software Precision para estructuras de cerebro y cabeza y cuello, utilizando los sets de imágenes disponibles en la base de datos del software. Se midió la precisión de la delimitación realizada a cada uno de los sets de imágenes, descartando su uso por el sistema y utilizando los demás atlas para realizar la autosegmentación, método que se conoce como leave-one-out cross validation, en inglés, o validación cruzada dejando-uno-fuera, en español. En las tablas 6 y 7 se pueden ver los resultados para cerebro y cabeza y cuello, respectivamente, representados como el error promedio de superficie, que es la diferencia de distancia entre las superficies de las estructuras en los sets de imágenes comparados [11].

Se estimó que el tiempo aproximado de contorneo de estructuras cerebrales, hecho por un neuroanatomista, es de 4 días, mientras que el software genera las delimitaciones en aproximadamente 3 minutos [11].



Anatomical Structure	Mean Surface Error $\pm$ SD (mm)
All Central Brain Structures	0.5 $\pm$ 0.1
All Cortical Brain Structures	0.9 $\pm$ 0.1
Brainstem	0.3 $\pm$ 0.0
Optic Chiasm	0.3 $\pm$ 0.2
Thalamus	0.4 $\pm$ 0.1
Hippocampus	0.5 $\pm$ 0.3
Amygdala	0.4 $\pm$ 0.1
Accumbens	0.4 $\pm$ 0.1
Caudate	0.4 $\pm$ 0.2
Putamen	0.3 $\pm$ 0.0
Pallidum	0.3 $\pm$ 0.0
Ventral Diencephalon	0.3 $\pm$ 0.0
Precentral Gyrus	0.9 $\pm$ 0.5
Postcentral Gyrus	1.1 $\pm$ 0.5
Inferior Temporal Gyrus	0.9 $\pm$ 0.3
Middle Temporal Gyrus	0.9 $\pm$ 0.3
Superior Temporal Gyrus	0.9 $\pm$ 0.5
Transverse Temporal Gyrus	0.9 $\pm$ 1.0

Tabla 6, precisión de la autosegmentación de cerebro basada en imágenes de RM potenciadas en T1 (N=20). [11]

Anatomical Structure	Mean Surface Error $\pm$ SD (mm)
Whole Brain	0.4 $\pm$ 0.1
Brainstem	1.0 $\pm$ 0.4
Mandible	0.5 $\pm$ 0.2
Spinal Cord	0.7 $\pm$ 0.2
Spinal Canal	0.7 $\pm$ 0.2
Globes	0.5 $\pm$ 0.2
Lenses	0.5 $\pm$ 0.2
Optic Nerves	0.6 $\pm$ 0.1
Optic Chiasm	1.3 $\pm$ 0.3
Larynx	1.3 $\pm$ 0.6
Parotids	1.6 $\pm$ 0.6
Precentral Gyrus	0.9 $\pm$ 0.5
Postcentral Gyrus	1.1 $\pm$ 0.5
Inferior Temporal Gyrus	0.9 $\pm$ 0.3
Middle Temporal Gyrus	0.9 $\pm$ 0.3
Superior Temporal Gyrus	0.9 $\pm$ 0.5
Transverse Temporal Gyrus	0.9 $\pm$ 1.0

Tabla 7, precisión de la autosegmentación de cabeza y cuello basada en imágenes de TC (N=36). [11]

En el caso de las imágenes de RM cerebral potenciadas en T1, se obtuvo que el software tiene un error promedio de superficie de 0,5 mm para estructuras cerebrales centrales y de 0,9 mm para estructuras corticales. La estructura con menor error promedio de superficie fueron varias, entre ellas el quiasma óptico, putamen y tronco encefálico, con 0,3 mm, mientras que la estructura con mayor error fueron el giro postcentral, con 1,1 mm.

Respecto a imágenes de TC de cabeza y cuello, el promedio del error promedio de superficie fue de 0,827 mm, sin tomar en cuenta estructuras corticales cerebrales, respecto a las cuales, al igual que en la delimitación de cerebro, se obtuvo que el error promedio de superficie es de 0,9 mm. La estructura con menor error promedio de superficie fue el cerebro completo, con 0,4 mm, mientras que la estructura con mayor error fueron las glándulas parótidas, con 1,6 mm.

### 6.2.3. SPICE de Philips


Smart Probabilistic Image Contouring Engine, o SPICE, es el motor de autosegmentación de Pinnacle hasta su versión 9.4, software de planificación de tratamiento de la marca Philips, el cual es un software universal, es decir, puede funcionar para cualquier equipo, no solo de la marca Philips. Este motor utiliza una metodología híbrida para realizar el registro de las imágenes, tanto basado en atlas como basado en modelos, siendo este último un método basado en la utilización de representaciones tridimensionales de las estructuras de interés específicas [3,12]. Este motor es capaz de delimitar estructuras de cabeza y cuello, tórax, abdomen y pelvis masculina, las cuales están desplegadas en la tabla 8. Además, para evitar errores asociados a variaciones interpaciente, se han adicionado atlas que presentan algunas variantes anatómicas [13].

SPICE atlases and structures	
<b>Head and neck</b>	<b>Lung/thorax</b>
<ul style="list-style-type: none"><li>• Brain</li><li>• Brainstem</li><li>• Brain with brainstem</li><li>• Glottis</li><li>• Left and right acoustic nerves</li><li>• Left and right cochleae</li><li>• Left and right eyes</li><li>• Left and right eye lens</li><li>• Left and right neck nodes</li><li>• Left and right optic nerves</li><li>• Left and right parotids</li><li>• Left and right parotids with ducts</li><li>• Left and right submandibular glands</li><li>• Mandible</li><li>• Optic chiasm</li><li>• Oral cavity</li><li>• Pharyngeal constrictor</li><li>• Skin (external)</li><li>• Soft palate</li><li>• Spinal canal and spinal cord</li><li>• Sublingual glands</li><li>• Thyroid gland</li></ul>	<ul style="list-style-type: none"><li>• Carina</li><li>• Heart</li><li>• Left and right lungs</li><li>• Skin (external)</li><li>• Spinal canal and spinal cord</li><li>• Trachea</li></ul>
	<b>Abdomen</b>
	<ul style="list-style-type: none"><li>• Left and right kidneys</li><li>• Liver</li><li>• Skin (external)</li><li>• Spinal canal and spinal cord</li></ul>
	<b>Male pelvis</b>
	<ul style="list-style-type: none"><li>• Bladder</li><li>• Prostate</li><li>• Rectum</li><li>• Left and right femoral heads</li><li>• Seminal vesicles</li><li>• Skin (external)</li></ul>

*Tabla 8, estructuras disponible para la autosegmentación de SPICE. [13]*

SPICE dispone de dos vías de algoritmos distintos, uno para delimitar tórax, cabeza y cuello; y uno para abdomen y pelvis masculina. A través de estas vías, la imagen a deformar será llevada a distintos algoritmos para procesarse, siendo 3 los pasos principales para ambos algoritmos, sin embargo, no son los mismos pasos [13].

La vía de tórax, cabeza y cuello consiste en, primero, un registro deformable de acuerdo a 14 puntos de interés, con el fin de alinear la imagen del atlas con la del paciente, compensando diferencias en el posicionamiento. Luego, es aplicado un algoritmo de registro deformable llamado Enhanced Demons, que iniciará la deformación de órganos para, finalmente, dar paso a la realización del registro basado en modelo y el perfeccionamiento probabilístico. Lo que hace el registro basado en modelo, es suavizar la delimitación realizada por Enhanced Demons, utilizando modelos específicos de órganos y adaptándose a las características del paciente. En la imagen 2 se aprecia la diferencia entre la delimitación realizada solo por Demons (línea azul) y después de aplicar el registro basado en modelo (línea amarilla), siendo evidente el cambio, dado que en un inicio se solapaba parte de la mandíbula y se engloba un espacio considerable fuera de la glándula parótida. Luego, la delimitación se termina de refinar mediante el uso de 'límites de incertidumbre', dentro de los cuales se puede deformar la imagen manteniendo valores óptimos de similaridad [13].

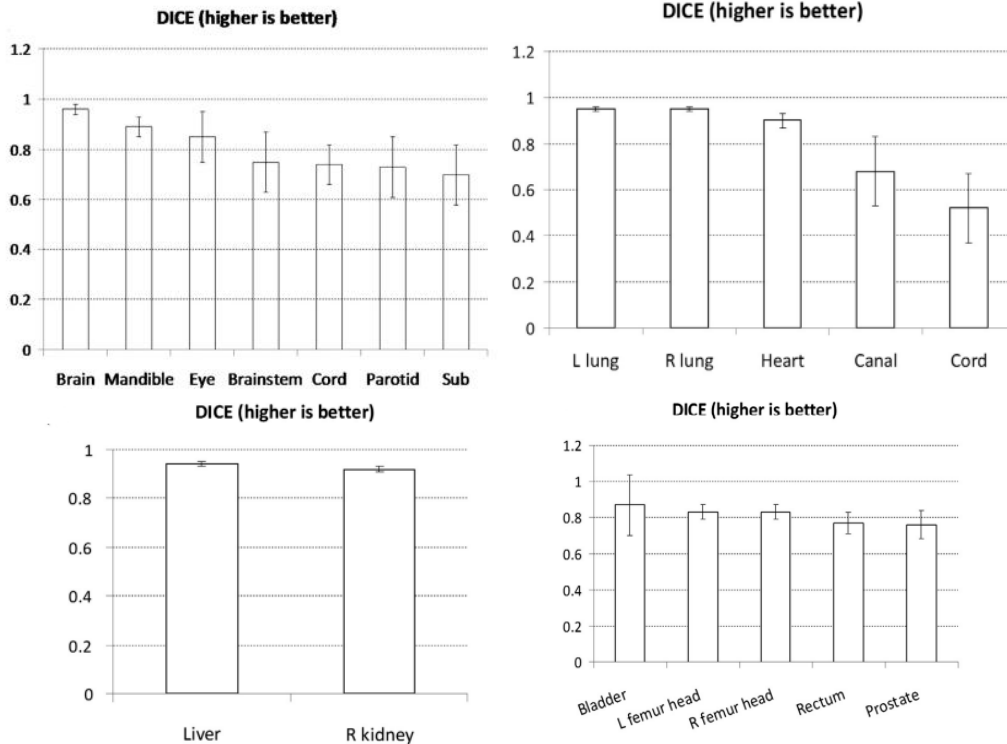


*Imagen 2, delimitación hecha por Enhanced Demons (línea azul) y luego del registro basado en modelo (línea amarilla). [13]*

La segunda vía de algoritmos está destinada a la delimitación de abdomen y pelvis masculina, y parte con la realización de un registro afin, que rotará y escalará el atlas respecto al paciente, pero no habrá un buen solapamiento de las estructuras. Para corregir esto, se hace un registro deformable, el cual posicionará de manera simultánea los distintos órganos y estructuras, utilizando mapas de probabilidad específicos para cada una de ellas. Finalmente, se aplicará un registro basado en modelos, para terminar de refinar la delimitación, de la misma manera que en la vía de algoritmos para tórax, cabeza y cuello, solo que sin aplicar los 'límites de incertidumbre' [13].

En un estudio de Zhu, M., et al, del año 2013, se realiza una evaluación cuantitativa y validación clínica del uso de SPICE para contornear estructuras de riesgo en cabeza y cuello, tórax, abdomen y pelvis masculina, en sets de imágenes de TAC de 125 pacientes de 7 centros de salud distintos, 3 centros europeos y 4 norteamericanos. Dichos sets de imágenes ya habían sido contorneados por expertos, para ser utilizados para planificar sus respectivos tratamientos. Se dispuso de 32 TAC de cabeza y cuello, 40 TAC de tórax, 23 TAC de abdomen y 30 TAC de pelvis masculina. Se comparó la delimitación realizada por SPICE y aquella de los expertos, utilizando el coeficiente de Sorensen-Dice (CSD) para cuantificar la precisión. Los resultados de este estudio están en los gráficos 1 a 4 [14].

Por otro lado, se hicieron mediciones del tiempo en que SPICE realizó las delimitaciones, demorándose, de manera aproximada, 11' 6" para delimitar cabeza y cuello, 3' 6" para tórax, 6' 36" para abdomen y 3' 42" para pelvis masculina [14]. De acuerdo a los desarrolladores, Philips Electronics, durante las pruebas de fábrica del motor se obtuvo el tiempo en que este se demoraba en realizar las delimitaciones, siendo de 5' 22" para cabeza y cuello (104 cortes), 2' 51" para tórax (107 cortes), 6' 3" para abdomen (110 cortes) y 2' 48" para pelvis masculina (99 cortes) [15].



Gráficos 1 y 2 (arriba), 3 y 4 (abajo), representan los valores del coeficiente de Sorensen-Dice para cabeza y cuello, tórax, abdomen y pelvis masculina, respectivamente. [14]

Para las mediciones de cabeza y cuello, se obtuvo un valor promedio de CSD de 0,8014. La estructura mejor evaluada fue el cerebro, con un valor de 0,96, mientras que la estructura peor evaluada fueron los linfonodos submandibulares, con un valor de 0,7.

Para tórax, se obtuvo un valor promedio de CSD de 0,8. Las estructuras mejor evaluadas fueron ambos pulmones, ambos con un valor de 0,95, mientras que la estructura peor evaluada fue la médula espinal, con un valor de 0,52.

Para abdomen, se obtuvo un valor promedio de CSD de 0,9033. La estructura mejor evaluada fue el hígado, con un valor de 0.94, mientras que la peor evaluada fue el riñón izquierdo, con un valor de 0,85 (no aparece en el gráfico).

Finalmente, para pelvis masculina, se obtuvo un valor promedio de CSD de 0,8075. La estructura mejor evaluada fue la vejiga, con un valor de 0,87, mientras que la peor evaluada fue la próstata, con un valor de 0,76.

## 7. Discusión

El uso de motores de autosegmentación permite un ahorro sustancial de tiempo a la hora de delimitar estructuras de riesgo e, incluso, volúmenes de tratamiento, reduciendo el trabajo de horas, o incluso días, a unos pocos minutos, lo que implica que se agilice el proceso de planificación de tratamientos, permitiendo que se pueda planificar más pacientes en un tiempo menor [1,2,3]. Esto, claramente, también es beneficioso para los pacientes, quienes podrán empezar antes sus tratamientos. Tomando como referencia la delimitación de cabeza y cuello, un estudio determinó que el contorno manual toma, aproximadamente, 2 horas y 46 minutos [14]. A SPICE y ABAS, que fueron aquellos sistemas en los que se evaluó en tiempo que demoran en delimitar imágenes de cabeza y cuello, les tomó, en promedio, 11 minutos y 2 segundos, esto sin tomar en cuenta las mediciones de fábrica. Esto implicaría un ahorro de tiempo de 2 horas y 35 minutos, es decir, una reducción del 89,6%.

Es complicado llegar a un consenso de qué es una delimitación clínicamente aceptable, ya que no existe una estructura fija, definitiva, con la cual comparar los valores de distancia promedio de superficie o coeficiente de Sorensen-Dice. Además, está documentado solo un estudio a gran escala con un sistema de autosegmentación basado en atlas, SPICE, utilizando TAC de 125 pacientes de 7 centros de salud distintos, 3 centros europeos y 4 norteamericanos. Dicho estudio está referido en esta revisión [14]. De todas maneras, realizar un estudio multi-institucional con imágenes de pacientes de diversas regiones del planeta es complicado, dado que, al manejar grandes cantidades de información, se requeriría que múltiples expertos realicen la delimitación manual de estructuras para comparar aquellas realizadas por el sistema con contornos 'verdaderos', lo cual consumiría muchos recursos [14].

Estos sistemas, a pesar de lograr valores considerados aceptables de acuerdo a lo concluido en los artículos revisados [7,8,11,14], no se ven exentos a errores, los cuales pueden intrínsecos al uso de atlas para realizar las delimitaciones, la cantidad de atlas utilizados o a la métrica de similaridad utilizada por el software [2,3,5]. Debido que no existe un atlas universal, la variabilidad interpaciente es un factor muy importante que tomar en cuenta, ya que no todos los pacientes van a tener características similares, lo cual puede deberse a variantes anatómicas, hipertrofias, presencia de endoprótesis, catéteres, etc. El uso de multi-atlas es una manera de amortiguar este problema, fusionando delimitaciones hechas a distintos atlas para corregir dichas imprecisiones y obtener contorneos 'promedio', por lo que, mientras más atlas sean utilizados, más fidedigna será la autosegmentación realizada por el software [7,16]. Algunos motores, como SPICE, poseen atlas que presentan variantes anatómicas específicas [13], mientras que otros, como ABAS con STAPLE, permiten utilizar como atlas a pacientes planificados anteriormente y fusionar tantos atlas como se estime necesario [7,8].

Por otro lado, la métrica de similaridad utilizada por el software también juega un rol importante en la precisión de la delimitación de estructuras, ya que, por ejemplo, si utilizamos una métrica basada en intensidad, aquellas estructuras que posean un bajo contraste en la imagen van a tener márgenes erróneos o incluso irreales, como puede pasar con estructuras como la próstata, el margen posterior de la vejiga, glándulas parótidas, glándulas submandibulares, quiasma óptico o estructuras cerebrales. De hecho, estas últimas, como en el caso de Precision de Accuray, son delimitadas utilizando imágenes de resonancia nuclear magnética potenciadas en T1 [9], ya que, debido a su buena resolución de contraste, tiene la capacidad de discernir entre estructuras con relativa facilidad, permitiendo contornear estructuras que directamente no se pueden distinguir en una adquisición de TC, como pueden ser el putamen, globo pálido, núcleo caudado, hipocampo, tálamo, etc.

La calidad de la delimitación está también sujeta al consenso de los observadores, es decir, los profesionales a cargo deben estar de acuerdo con que la delimitación obtenida sea adecuada para la realización del tratamiento. Si no se llega a un consenso, se deberá realizar modificaciones manuales a las delimitaciones, lo cual aumentará la correspondencia entre imágenes [8,17]. Por otro lado, el tiempo que demore la realización de la delimitación va a depender también de qué tantas modificaciones sea necesario realizar [17].

Dependiendo del desarrollador, estos equipos pueden ser universales o compatibles con equipos de la misma compañía desarrolladora. Por ejemplo, SPICE y ABAS son de uso universal, son compatibles con cualquier equipo, mientras que Precision es solo compatible con los equipos Radixact y Cyberknife de Accuray. Este es un factor importante que tomar en cuenta al adquirir uno de estos sistemas, ya que se podría estar comprando un software que no es compatible con los equipos disponibles en el centro.



## 8. Conclusiones

Los sistemas de autosegmentación basados en atlas han tenido un gran desarrollo dentro de la última década, permitiendo la existencia de diversos softwares disponibles en el mercado, los cuales tienen la capacidad de delimitar estructuras anatómicas en un tiempo acotado y con cierto grado de precisión. Sin embargo, a pesar de ser los sistemas de autosegmentación más masificados, no son los más sofisticados. Esta etiqueta les corresponde a los sistemas de autosegmentación basados en deep learning [1,3].

A grandes rasgos, los sistemas basados en deep learning tienen la capacidad de integrar la información entregada a su base de datos de manera autónoma, analizando, abstrayendo y determinando las relaciones entre sus partes, las cuales serán ordenadas y jerarquizadas en distintos nódulos y niveles, lo que se conoce como una red neural profunda [3,4,18]. Por ejemplo, si a uno de estos sistemas lo 'alimentamos' con imágenes de atlas de cabeza y cuello, este tomará sus diferentes estructuras, ya sea grupos de linfonodos, glándulas salivales u otras, y aislará su información, pudiendo determinar tendencias de diversas características, que corresponden a diferentes nódulos en la red, como su ubicación, dimensiones, extensión, estructuras colindantes, etc. Entonces, cuando se le entrega un set de imágenes para delimitar, ocupará aquella información abstraída previamente para crear una imagen simulada, la cual se comparará con las imágenes del paciente y se iterará hasta obtener una delimitación lo más cercana posible a estas [3,4,18].

En la Fundación Arturo López Pérez (FALP), se está implementando el uso de Limbus, un sistema de autosegmentación basado en deep learning, el cual tiene la capacidad de realizar la delimitación de imágenes de cabeza y cuello en menos de 3 minutos, con una precisión tal que apenas requiere de modificaciones manuales.

Para finalizar, cabe recalcar que, independiente de la naturaleza del software utilizado para realizar la delimitación y qué tan confiable pueda ser el resultado del proceso, siempre es recomendable, si no imperativo, revisar los contornos y realizar ediciones manuales, si fueren necesarias, para que la delimitación de volúmenes sea lo más fidedigna posible. Si bien las delimitaciones se realizan en un tiempo acotado, es posible que algunas estructuras no queden bien delimitadas, viéndose alteradas ya sea por presencia de un tumor o por cambios posoperatorios. Si no existe una correcta revisión de las delimitaciones, puede que haya diferencias de volumen significativas entre la estructura real y lo contorneado, pudiendo alterar completamente la dosimetría.

## 9. Bibliografía

- 1) Harrison, K., Pullen, H., Welsh, C., Oktay, O., Alvarez-Valle, J., Jena, R. (2022). *Machine Learning for Auto-Segmentation in Radiotherapy Planning*. Clin Oncol (R Coll Radiol). 2022 Feb;34(2):74-88. doi: 10.1016/j.clon.2021.12.003. Epub 2022 Jan 5. PMID: 34996682.
- 2) Iglesias, J. E., & Sabuncu, M. R. (2015). *Multi-atlas segmentation of biomedical images: A survey*. *Medical Image Analysis*, 24(1), 205–219. doi:10.1016/j.media.2015.06.012
- 3) Cardenas, C. E., Yang, J., Anderson, B. M., Court, L. E., & Brock, K. B. (2019). *Advances in Auto-Segmentation*. *Seminars in Radiation Oncology*, 29(3), 185–197. doi:10.1016/j.semradonc.2019.02.001
- 4) Park, S., Chu, L.C., Fishman, E.K., Yuille, A.L., Vogelstein, B., Kinzler, K.W., Horton, K.M., Hruban, R.H., Zinreich, E.S., Fadaei, D., Shayesteh, S., Graves, J. & Kawamoto, S. (2020). *Annotated normal CT data of the abdomen for deep learning: Challenges and strategies for implementation*. *Diagnostic and Interventional Imaging*, Vol. 101. p. 35 - 44.
- 5) Brock, K. K., Mutic, S., McNutt, T. R., Li, H., & Kessler, M. L. (2017). *Use of image registration and fusion algorithms and techniques in radiotherapy: Report of the AAPM Radiation Therapy Committee Task Group No. 132*. *Medical Physics*, 44(7), e43–e76. doi:10.1002/mp.12256
- 6) Acosta O., Dowling, J., Drean, G., Simon, A., De Crevoisier, R., et al. (2013). *Multi-atlas-based segmentation of pelvic structures from CT scans for planning in prostate cancer radiotherapy*. Ayman S. El-Baz; Luca Saba; Jasjit Suri. *Abdomen and Thoracic Imaging*, Springer US, pp.623-656.

- 7) Anders, L. C., Stieler, F., Siebenlist, K., Schäfer, J., Lohr, F., & Wenz, F. (2012). *Performance of an atlas-based autosegmentation software for delineation of target volumes for radiotherapy of breast and anorectal cancer. Radiotherapy and Oncology, 102(1), 68–73.* doi:10.1016/j.radonc.2011.08.043
- 8) La Macchia, M., Fellin, F., Amichetti, M., Cianchetti, M., Gianolini, S., Paola, V., Widesott, L. (2012). *Systematic evaluation of three different commercial software solutions for automatic segmentation for adaptive therapy in head-and-neck, prostate and pleural cancer. Radiation Oncology, 7(1), 160.* doi:10.1186/1748-717x-7-160
- 9) Accuray ® Center for Education (2020). *Accuray Precision ® Treatment Planning for the CyberKnife ® System.* p. 65 – 79.
- 10) Accuray ® Center for Education (2020). *Accuray Precision ® Treatment Planning for the Radixact ® System.* p. 31.
- 11) Jordan, P., Myronenko, A., Gorcowski, K., Foskey, M., Holloway, R., Maurer, Jr, C. (2017). *Accuray Deformable Image Registration: Description and Evaluation.* Accuray Incorporated.
- 12) Heimann, T., Delingette, H. (2013). *Model-based segmentation.* Deserno, Thomas Martin. Biomedical Image Processing, Springer, pp.279-303, 2011, 978-3-642-15815-5. ff10.1007/978-3-642-15816-2\_11ff. ffinria-00616063f
- 13) Bzdusek, K., Bystrov, D., Pekar, V., Peters, J., Schadevaldt, N., Schulz, H., Vik, T. (2012). *Smart Probabilistic Image Contouring Engine (SPICE).* Philips Research y Philips Healthcare.

- 14) Zhu, M., Bzdusek, K., Brink, C., Eriksen, J.G., Hansen, O., Jensen, H.A., Gay, H.A., Thorstad, W., Widder, J., Brouwer, C.L., Steenbakkens, R.J., Vanhauten, H.A., Cao, J.Q., McBrayne, G., Patel, S.H., Cannon, D.M., Hardcastle, N., Tomé, W.A., Guckenberger, M., Parikh, P.J. (2013). *Multi-institutional quantitative evaluation and clinical validation of Smart Probabilistic Image Contouring Engine (SPICE) autosegmentation of target structures and normal tissues on computer tomography images in the head and neck, thorax, liver, and male pelvis areas*. Int J Radiat Oncol Biol Phys. 2013 Nov 15;87(4):809-16. doi: 10.1016/j.ijrobp.2013.08.007. PMID: 24138920.
- 15) Philips Electronics. (2012). *Philips Pinnacle3 Auto-Segmentation with SPICE, frequently asked questions*.
- 16) Schipaanboord, B., Boukerroui, D., Peressutti, D., van Soest, J., Lustberg, T., Kadir, T., Gooding, M. (2018). *Can atlas-based auto-segmentation ever be perfect? Insights from Extreme Value Theory*. IEEE Transactions on Medical Imaging, 1–1. doi:10.1109/tmi.2018.2856464
- 17) Langmack, K. A., Perry, C., Sinstead, C., Mills, J., & Saunders, D. (2014). *The utility of atlas-assisted segmentation in the male pelvis is dependent on the interobserver agreement of the structures segmented*. The British Journal of Radiology, 87(1043), 20140299. doi:10.1259/bjr.20140299
- 18) Vrtovec, T., Močnik, D., Strojjan, P., Pernuš, F., & Ibragimov, B. (2020). *Auto-segmentation of organs at risk for head and neck radiotherapy planning: from atlas-based to deep learning methods*. Medical Physics. doi:10.1002/mp.14320

- 19) Ramus, L., & Malandain, G. (2010). *Assessing selection methods in the context of multi-atlas based segmentation. 2010 IEEE International Symposium on Biomedical Imaging: From Nano to Macro*. doi:10.1109/isbi.2010.5490240
- 20) Harari, P. M., Song, S., & Tomé, W. A. (2010). *Emphasizing Conformal Avoidance Versus Target Definition for IMRT Planning in Head-and-Neck Cancer. International Journal of Radiation Oncology\*Biology\*Physics, 77(3), 950–958*. doi:10.1016/j.ijrobp.2009.09.062

## 10. Anexos:



### AUTORIZACIÓN DE ENTREGA DE REVISIÓN BIBLIOGRÁFICA

El abajo firmante autoriza la entrega de la Revisión bibliográfica titulada: Uso de sistemas de autosegmentación basados en atlas para delimitación de estructuras en planificación de tratamientos en radioterapia avanzada, desarrollada por Nicolás Andrés Lucero Guerra, estudiante(s) de Tecnología Médica de la Universidad de Chile.

Nombre...ALEXIS TRONCOSO VICENCIO

Cargo: TECNOLOGO MEDICO

Unidad académica o servicio: .....DEPARTAMENTO DE TECNOLOGIA MEDICA.

Teléfono: .....+56995267607

e-mail: ...atroncosov@uchile.cl

Fecha : .....28-11-22.. Firma : .....