

Three-Dimensional Segmentation of Cosmological Simulations for Cosmic Void Detection

Julieta Paola Storino^{1,2} , Ignacio Germán Alfaro^{2,4} , Andrés Nicolás Ruiz^{1,2} , Dante Javier Paz^{1,2} , and Juan Bautista Cabral^{1,3} 

¹ Facultad de Matemática, Astronomía, Física y Computación, UNC.

² Instituto de Astronomía Teórica y Experimental, CONICET-UNC.

³ Comisión Nacional de Actividades Espaciales.

⁴ Departamento de Física, Universidad Técnica Federico Santa María.

⁵ Observatorio Astronómico de Córdoba, UNC.

julieta_storino@mi.unc.edu.ar

Abstract. The Large-Scale Structure of the Universe exhibits a complex organization composed of filaments, sheets, and clusters separated by cosmic voids, which are underdense regions that play a fundamental role in the study of cosmology and the formation and evolution of galaxies. However, their identification remains a significant challenge due to the lack of a unique definition and the complexity of their morphology. In this context, this work proposes adapting the image segmentation foundation model Segment Anything Model (SAM) for the detection of cosmic voids in three-dimensional matter distribution simulations, evaluating its performance in a zero-shot setting and comparing it with the classical Spherical Void Finder (SVF) method, with emphasis on its ability to capture complex morphologies and characterize their physical properties.

Keywords: cosmic voids, 3D segmentation, Segment Anything Model (SAM), foundation models, astroinformatics

Segmentación Tridimensional en Simulaciones Cosmológicas para la Detección de Vacíos Cósmicos

Abstract. La Estructura a Gran Escala del Universo constituye una compleja red compuesta por filamentos, láminas y cúmulos separados por vacíos cósmicos, regiones subdensas fundamentales para el estudio de la cosmología y la formación y evolución de galaxias. Sin embargo, su identificación continúa siendo un desafío debido a la ausencia de una definición única y a la complejidad de su morfología. En este contexto, el

presente trabajo propone adaptar el modelo de segmentación de imágenes *Segment Anything Model* (SAM) para la detección de vacíos cósmicos en simulaciones tridimensionales, evaluando su desempeño en un esquema *zero-shot* y comparándolo con el método clásico *Spherical Void Finder* (SVF), con énfasis en su capacidad para capturar morfologías complejas y caracterizar sus propiedades físicas.

Keywords: vacíos cósmicos, segmentación 3D, Segment Anything Model (SAM), modelos fundacionales, astroinformática

1 Introducción

A muy grandes escalas, el Universo presenta una estructura conocida como red cósmica, donde la materia se organiza en filamentos, paredes, cúmulos y vacíos. Estos últimos ocupan gran parte del volumen del Universo y constituyen una herramienta valiosa para estudiar la expansión, la geometría y la evolución del mismo (Correa, 2021), además de ofrecer entornos privilegiados para estudiar la formación y evolución de galaxias, así como las propiedades de las galaxias que habitan regiones de baja densidad (Alfaro et al., 2020). No obstante, su identificación es compleja debido a la ausencia de una definición única y a la dependencia de los métodos y trazadores empleados.

Entre las propuestas más utilizados para su detección se encuentra *ZOnes Bordering On Voidness* (ZOBOV) (Neyrinck, 2008), un algoritmo topológico tipo *watershed* que identifica regiones subdensas sin parámetros libres y permite estimar su significancia estadística y jerarquía estructural, pero no reproduce adecuadamente las propiedades físicas descritas en la teoría. Por otro lado, la familia de métodos *Spherical Void Finder* (SVF) (Colberg et al., 2005; Padilla et al., 2005; Ruiz et al., 2015) modela los vacíos como esferas subdensas, facilitando su caracterización mediante parámetros simples como centro y radio, aunque limitando la representación de morfologías complejas. Por último, la estrategia *Popcorn Void Finder* (PVF) (Paz et al., 2023) extiende este enfoque mediante la agregación recursiva de esferas, logrando mayor flexibilidad geométrica a costa de un mayor costo computacional.

En este contexto, la segmentación de imágenes aplicada a campos de densidad constituye una alternativa a los identificadores clásicos basados en trazadores puntuales, ya que permite trabajar sobre representaciones continuas del campo y detectar regiones subdensas con geometría arbitraria.

2 Simulaciones de N -cuerpos

El modelo cosmológico más aceptado en la actualidad es el Λ CDM, que describe la composición del Universo en términos de materia bariónica, materia oscura

fría, radiación y energía oscura. En este marco, la materia oscura fría, que interactúa únicamente mediante la gravedad, desempeña un papel fundamental en la formación de la Estructura a Gran Escala (LSS). Para estudiar este proceso, las simulaciones de N -cuerpos representan la distribución de materia oscura fría mediante partículas cuya evolución gravitatoria se calcula a partir de condiciones iniciales compatibles con Λ CDM. Además, al incorporar condiciones de contorno periódicas, permiten aproximar de manera consistente una región representativa de la LSS.

La evolución de estas simulaciones está determinada por un conjunto reducido de parámetros fundamentales, denominados parámetros cosmológicos (Planck Collaboration: Aghanim et al., 2020), que describen la composición del Universo y fijan las condiciones físicas del modelo. Entre ellos, el parámetro de densidad de materia,

$$\Omega_m = \frac{\rho_m}{\rho_c},$$

relaciona la densidad total de materia (ρ_m) con la densidad crítica del Universo (ρ_c), utilizada como referencia para normalizar las densidades cosmológicas. Este parámetro cuantifica la contribución de la materia a la densidad total del Universo y controla la formación y evolución de la LSS.

2.1 Caracterización de vacíos cósmicos

La caracterización estadística de los vacíos cósmicos resulta fundamental para describir sus propiedades globales y confrontarlas con predicciones teóricas. Una de las mas estudiadas es la *Función de Tamaño de Vacío* (VSF), la cual cuantifica la abundancia de vacíos según su distribución de tamaños. Formalmente, la VSF se define como la densidad numérica de estas estructuras por unidad de intervalo logarítmico de tamaños,

$$A_v(R_v) := \frac{dn_v}{d\ln R_v} = \frac{1}{V} \frac{dN_v}{d\ln R_v},$$

donde dN_v representa el número de vacíos con logaritmo natural del radio en el rango comprendido entre $\ln(R_v)$ y $\ln R_v + d\ln R_v$, y V el volumen total de la región analizada. Dado que los vacíos presentan geometrías inherentemente irregulares, para comparar de manera consistente distintas delimitaciones, se utiliza el *radio equivalente* o *radio característico*, definido como el radio de una esfera cuyo volumen es idéntico al volumen total de la región subdensa V_v ,

$$R_v(V_v) = \left(\frac{3V_v}{4\pi} \right)^{1/3}.$$

Asimismo, resulta relevante considerar la densidad integrada dentro del volumen ocupado por el vacío, parámetro que permite determinar si una región subdensa se comporta dinámicamente como un vacío según modelos teóricos

de colapso y expansión, constituyendo además la base sobre la cual operan los distintos algoritmos de identificación. Este contraste se define como,

$$\Delta_v(R_v) = \frac{3}{4\pi R_v^3} \int_0^{R_v} \delta(\mathbf{x}) 4\pi r^2 dr.$$

2.2 Caracterización del campo de densidad

Para identificar estructuras en simulaciones de N -cuerpos, transformamos la distribución puntual de partículas en un campo de densidad definido sobre una grilla regular que cubre el volumen de la simulación. A cada celda de la grilla, centrada en la posición $\mathbf{p}$, se le asigna una densidad utilizando el número de partículas contenidas en la celda ($N(\mathbf{p})$) y su volumen (V_c). Esta densidad se define como,

$$\rho(\mathbf{p}) = \frac{N(\mathbf{p})}{V_c}.$$

A partir de este campo se introduce el contraste de densidad (δ), que permite cuantificar las fluctuaciones locales respecto de la densidad media del Universo. En particular, toma valores negativos ($-1 \leq \delta < 0$) en regiones correspondientes a vacíos y valores positivos elevados en nodos y filamentos. Este contraste se define como,

$$\delta(\mathbf{p}) = \frac{\rho(\mathbf{p})}{\langle \rho \rangle} - 1.$$

Sobre la base del contraste de densidad puede definirse la densidad integrada dentro del volumen ocupado por un conjunto continuo de celdas $\mathcal{V}$, lo que permite caracterizar regiones extendidas como vacíos segmentados. En este trabajo se adopta la siguiente definición,

$$\Delta_v(\mathcal{V}) = \frac{1}{N_{\mathcal{V}}} \sum_{\mathbf{p}' \in \mathcal{V}} \delta(\mathbf{p}').$$

3 Segmentación de Instancias

La segmentación de instancias es una tarea de visión por computadora que consiste en identificar cada objeto individual presente en una imagen y determinar los píxeles que le corresponden, distinguiendo entre instancias de una misma clase. Para ello, combina la detección de objetos mediante cuadros delimitadores con la asignación de etiquetas a nivel de píxel. En este trabajo, esta tarea se aborda mediante arquitecturas basadas en *Vision Transformers*, capaces de modelar de manera eficiente relaciones espaciales de largo alcance y que han demostrado un desempeño destacado en tareas de segmentación.

3.1 Segment Anything Model (SAM)

SAM es un modelo fundacional de segmentación de imágenes diseñado para generalizar a nuevas tareas sin necesidad de reentrenamiento. Es guiado por *prompts*, permitiendo generar máscaras de segmentación a partir de distintos tipos de entrada, como puntos, cajas o máscaras iniciales. Para ello, utiliza una arquitectura (ilustrada en la Figura 1) compuesta por un codificador de imagen basado en ViT, un codificador de *prompts* y un decodificador de máscaras. El modelo fue entrenado con el conjunto de datos SA-1B, desarrollado específicamente para este proyecto, que contiene más de 1.000 millones de máscaras asociadas a 11 millones de imágenes.




Fig. 1. Arquitectura de SAM (Kirillov et al., 2023).

Sin embargo, dado que el entrenamiento de *SAM* no contempla imágenes correspondientes a campos de densidad, en este trabajo también se considera *MedSAM*, una variante del modelo original ajustada mediante *fine-tuning*. Este modelo fue entrenado sobre más de 1.57 millones de pares imagen-máscara, abarcando 10 modalidades médicas y más de 30 tipos de cáncer (Ma et al., 2024), lo que mejora su desempeño en escenarios caracterizados por bajo contraste y estructuras difusas. Esta capacidad de generalización lo convierte en una alternativa adecuada para explorar tareas de segmentación fuera de su dominio original. La arquitectura del modelo, ilustrada en la Figura 2, mantiene el diseño de *SAM*, integrando un codificador de imágenes, un codificador de *prompts* y un decodificador de máscaras.




Fig. 2. Arquitectura de MedSAM (Ma et al., 2024).

3.2 Métricas de calidad

Para evaluar el desempeño de los modelos en la detección de vacíos empleamos métricas de segmentación formuladas como un problema de clasificación binaria

(vacío o no vacío), comparando las máscaras predichas con el *ground truth*. A partir de esta comparación se construye la matriz de confusión, cuyos elementos principales son: verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN) (Sokolova and Lapalme, 2009).

A partir de estos valores se calculan métricas que resulten representativas para conjuntos desbalanceados como *precision* y *recall*, definidas como

$$\text{Precision} = \frac{TP}{TP + FP}, \quad \text{Recall} = \frac{TP}{TP + FN}, \quad \text{IoU} = \frac{TP}{TP + FP + FN},$$

junto con el índice de Jaccard, que cuantifica el solapamiento espacial entre la predicción y la verdad de campo penalizando simultáneamente FP y FN.

4 Descripción y procesamiento del conjunto de datos

En el desarrollo de este trabajo empleamos tres simulaciones cosmológicas de la LSS, correspondientes a un modelo plano de Λ CDM consistente con las estimaciones de la misión Planck (Planck Collaboration: Aghanim et al., 2020), que difieren únicamente en el valor del parámetro de densidad de materia, $\Omega_m = \{0.1; 0.3; 0.5\}$. Cada simulación está compuesta por 512^3 partículas de materia oscura dentro de un volumen cúbico de lado $500 h^{-1}$ Mpc. Estas partículas evolucionan en el tiempo bajo acción de la gravedad a partir de condiciones iniciales correspondientes al Universo temprano ($z \sim 50$). A partir de esta evolución se selecciona el *snapshot* en $z = 0$, que corresponde al tiempo actual.




Fig. 3. Vista ampliada del campo de densidad en el plano $z = 250.49 \text{ Mpc } h^{-1}$ con la proyección de los radios de los vacíos esféricos identificados.

Adicionalmente, empleamos catálogos de vacíos generados con el identificador SVF mediante la implementación *Sparkling*⁶, que identifica regiones esféricas no solapadas con contraste de densidad integrado $\Delta_v < -0.9$, produciendo catálogos que incluyen la posición del centroide, el radio característico (R_v), la velocidad

⁶ <https://gitlab.com/andresruiz/Sparkling>

evaluada en su centro y el valor del contraste de densidad Δ_v . Posteriormente, filtramos aquellas estructuras con $R_v < R_{\text{shot}} = 2.07 \text{ Mpc } h^{-1}$ a fin de excluir el ruido de muestreo. Los conjuntos finales, cuyas estadísticas se resumen en la Tabla 1, para $\Omega_m = \{0.1; 0.3; 0.5\}$ se denotan como Sparkling_Sim₁, Sparkling_Sim_f y Sparkling_Sim₅, respectivamente, donde el subíndice f indica el caso fiducial asociado al modelo cosmológico de referencia adoptado.

Catálogo	Ω_m	N _{voids}	R _{min}	R	R _{max}	Δ_{min}	Δ	Δ_{max}
Sparkling_Sim ₁	0.1	113 465	2.072	2.503	9.198	-0.919	-0.905	-0.900
Sparkling_Sim _f	0.3	233 857	2.072	2.767	11.859	-0.920	-0.905	-0.900
Sparkling_Sim ₅	0.5	241 080	2.072	2.934	12.526	-0.925	-0.904	-0.900

Table 1. Estadística descriptiva de los catálogos Sparkling_Sim₁, Sparkling_Sim_f y Sparkling_Sim₅. Los radios se expresan en $\text{Mpc } h^{-1}$.

4.1 Procesamiento y representación visual de los datos

Para tratar el campo de densidad como una imagen bidimensional extraemos cortes transversales de la grilla, sobre los cuales aplicamos una normalización del contraste de densidad mediante la transformación $\delta \mapsto \delta - \min(\delta) + \varepsilon$, con $\varepsilon \ll 1$, seguida de la compresión logarítmica $\delta \mapsto \log(1 + \delta)$, para reducir el rango dinámico y mejorar la discriminación de regiones subdensas. Posteriormente, incorporamos un relleno de tamaño `padding_size` que replica los bordes opuestos de cada lado. Finalmente el campo escalar se replica en los tres canales RGB y se redimensiona al formato tensorial requerido como entrada del *image encoder*.

4.2 Estrategias de segmentación

En este trabajo desarrollamos dos estrategias principales de *prompting*. En el primer enfoque, *Sliding Window* (SW), cada corte del campo de densidad se divide en ventanas cuadradas de tamaño fijo `window_size`, con solapamiento parcial entre ellas. Para cada ventana realizamos una inferencia utilizando como *prompt* la caja delimitadora correspondiente, previamente redimensionada al formato requerido por el modelo. Esto genera máscaras parciales que posteriormente se combinan mediante el valor máximo por píxel, lo que permite integrar las predicciones en regiones solapadas y preservar la continuidad espacial de las estructuras detectadas (como se ilustra en la Figura 4).

En el segundo enfoque *SVF bounding boxes* (SVF-BB), se utilizan los vacíos esféricos identificados con *Sparkling* que intersectan cada plano z . Para cada vacío con centro $\mathbf{p}$ y radio R_v , su proyección sobre el plano se modela mediante un círculo de radio

$$r_v(z) = \sqrt{R_v^2 - (z - p_z)^2},$$

considerando que cada corte tiene un espesor $\Delta z = 500/512 \text{ Mpc } h^{-1}$.

A partir de estos círculos se construyen cajas delimitadoras escaladas mediante el parámetro `box_scale`. Posteriormente, descartamos aquellas que quedan fuera de la imagen, así como las regiones solapadas, conservando




Fig. 4. Esquema del procedimiento de *Sliding Window*.

únicamente la asociada al mayor radio en cada caso. Finalmente, para evitar saturar el segmentador, el parámetro `box_size_threshold` establece un umbral de radio a partir del cual los vacíos se seleccionan para generar las cajas utilizadas como *prompts*. El conjunto resultante se emplea en la inferencia con SAM, como se ilustra en la Figura 5.




Fig. 5. Esquema del procedimiento de *SVF bounding boxes*.

4.3 Decodificación de máscaras

El decodificador de máscaras de SAM produce como salida un conjunto de *logits* de baja resolución que se interpolan a la resolución original y se transforman mediante una función sigmoide para obtener probabilidades, a partir de las cuales se genera una máscara binaria aplicando el umbral `segmentation_threshold`. Para identificar objetos individuales adoptamos un criterio de conectividad bidimensional entre píxeles adyacentes, extendido luego a cortes consecutivos en la dirección z mediante la agrupación de regiones con centroides conectados a través de caras, aristas o vértices, lo que permite reconstruir vacíos tridimensionales. Como resultado se obtiene un volumen segmentado donde cada celda de la grilla original contiene el identificador del

vacío al que corresponde o cero en caso de no pertenecer a ninguno, pudiéndose construir así catálogos de vacíos bidimensionales y tridimensionales de vacíos.

4.4 Marco de referencia para la evaluación

Con el objetivo de asignar un valor de verdad a los vacíos obtenidos mediante el proceso de segmentación, adoptamos dos criterios complementarios.

1. El *criterio físico* establece que un vacío se considera correctamente identificado cuando la densidad integrada sobre su volumen es negativa. Este criterio permite distinguir entre TP y FP a partir de una propiedad física de los vacíos sin proporcionar una caracterización completa de los casos restantes.
2. El *criterio geométrico* establece que un vacío se considera correctamente identificado cuando la región segmentada presenta una alta correspondencia espacial con los vacíos esféricos de los catálogos introducidos anteriormente. Este enfoque permite abordar la limitación anterior, aunque hereda restricciones asociadas a la discretización del campo de densidad.

Para establecer la correspondencia espacial entre los vacíos esféricos definidos sobre la distribución de partículas y los vacíos segmentados en el campo de densidad, se interpola la esfera para cada valor de z siguiendo un procedimiento análogo al utilizado en la generación de los *prompts*. Se consideran pertenecientes al vacío aquellos píxeles cuyo centro se encuentra dentro del radio esférico más una tolerancia.

5 Configuración experimental inicial

En la primera etapa trabajamos sobre un conjunto acotado de cortes de la simulación Sim_f , explorando visualmente distintas configuraciones de parámetros para cada método y modelo de segmentación. Esta fase permitió comprender el comportamiento general de los modelos y acotar los rangos de búsqueda de los parámetros, en función de la estabilidad y calidad de las segmentaciones obtenidas.

En el método *Sliding Window*, utilizamos exclusivamente el modelo MedSAM, ya que SAM no produjo segmentaciones utilizables en ninguna configuración. Para `padding_size` exploramos el rango 0–256 px, seleccionando 0, 64 y 256 px. Para `window_size` observamos fragmentación para valores < 16 px y unificación para valores > 32 px, por lo que adoptamos 16, 24 y 32 px. Finalmente, para `segmentation_threshold` seleccionamos 0.95, correspondiente al régimen más restrictivo previo a la aparición de ruido dominante.

En el método *SVF bounding boxes*, el parámetro `padding_size` mantuvimos en el mismo rango, seleccionándose 0, 64 y 256 px, con comportamiento más estable respecto del método anterior. Para `box_size_threshold` evaluamos cortes logarítmicos sobre la VSF, seleccionándose 2.07, 2.94 y $4.16 \text{ Mpc } h^{-1}$

debido a la pérdida de vacíos para valores mayores en algunas realizaciones. Para `box_scale` adoptamos 1.50, 1.75 y 2.00, y finalmente `segmentation_threshold` fijamos en 0.85 por su estabilidad visual en las segmentaciones obtenidas.

6 Evaluación parcial con muestreo aleatorio

En la segunda etapa implementamos una evaluación parcial sobre 50 cortes seleccionados aleatoriamente de la simulación Sim_f , con el objetivo de reducir la variabilidad estadística y analizar el comportamiento de las configuraciones candidatas en condiciones más representativas.

En el método *Sliding Window*, observamos que el incremento de `window_size` aumenta el radio promedio $\bar{R}$, alcanzando sus valores más altos para 32 px, mientras que `padding_size` reduce la presencia de estructuras pequeñas asociadas al ruido. Sin embargo, el contraste de densidad promedio $\bar{\Delta}$ se mantiene positivo en todas las configuraciones, indicando desviaciones respecto del comportamiento esperado de vacíos subdensos, aunque con una precisión física estable en el rango 0.69–0.75. En base a este comportamiento fijamos los parámetros finales `padding_size` = 128 px, `window_size` = 32 px y `segmentation_threshold` = 0.85.

En el método *SVF bounding boxes*, observamos que `box_size_threshold` incrementa la negatividad del contraste promedio mientras que `box_scale` introduce un efecto de dilución que reduce dicha negatividad, con influencia menor del parámetro `padding_size` sobre la estabilidad global. El modelo MedSAM presenta mayor dispersión en radios y mayor presencia de estructuras pequeñas, mientras que SAM genera distribuciones más compactas con radios mayores pero mayor variabilidad en contraste de densidad. La precisión global se mantiene entre 0.85 y 0.99, con mejor desempeño en regiones de mayor radio. En función de estos resultados fijamos los valores finales `padding_size` = 64 px, `box_size_threshold` = $4.16 \text{ Mpc } h^{-1}$, `box_scale` = 1.50 y `segmentation_threshold` = 0.50.

7 Desempeño global según las métricas de calidad estadísticas

En la (Tabla 2) se presentan las métricas geométricas utilizadas para evaluar cuantitativamente la calidad de las segmentaciones obtenidas. En el esquema *SVF Bounding Boxes* se observa que MedSAM presenta un mejor desempeño que SAM, debido a su *fine-tuning* en imágenes médicas, cuyas características morfológicas resultan más afines a las simulaciones cosmológicas utilizadas. Por otra parte, el método de *Sliding Windows* alcanza los mayores valores de *recall*, especialmente para umbrales bajos, lo que indica una mayor capacidad de cobertura de regiones subdensas. Este comportamiento contrasta con el enfoque basado en cajas, cuya segmentación queda restringida al interior de los *prompts*, priorizando precisión sobre cobertura.

Método	Modelo	Métrica	0.50	0.80	0.85	0.90	0.95	0.99
<i>SVF-BB</i>	MedSAM	<i>Precision</i>	0.582	0.670	0.691	0.716	0.754	0.822
<i>SVF-BB</i>	SAM	<i>Precision</i>	0.523	0.534	0.537	0.541	0.548	0.563
<i>SW</i>	MedSAM	<i>Precision</i>	0.281	0.292	0.296	0.291	0.298	0.318
<i>SVF-BB</i>	MedSAM	<i>Recall</i>	0.116	0.071	0.061	0.050	0.036	0.017
<i>SVF-BB</i>	SAM	<i>Recall</i>	0.184	0.179	0.177	0.176	0.173	0.168
<i>SW</i>	MedSAM	<i>Recall</i>	0.706	0.491	0.440	0.352	0.265	0.133
<i>SVF-BB</i>	MedSAM	<i>Jaccard</i>	0.107	0.069	0.060	0.049	0.035	0.016
<i>SVF-BB</i>	SAM	<i>Jaccard</i>	0.157	0.155	0.154	0.153	0.152	0.148
<i>SW</i>	MedSAM	<i>Jaccard</i>	0.251	0.224	0.215	0.189	0.163	0.104

Table 2. Métricas *Precision*, *Recall* y *Jaccard* evaluadas bajo el criterio geométrico en función del umbral `segmentation_threshold` para los distintos métodos y modelos de segmentación.

El índice de Jaccard permite complementar este análisis al cuantificar el solapamiento espacial entre las regiones segmentadas y las de referencia. En términos generales, el esquema de *Sliding Windows* presenta los valores más altos de solapamiento para umbrales intermedios, aunque las diferencias respecto de los otros enfoques son moderadas, lo que sugiere desempeños comparables desde el punto de vista geométrico. No obstante, al considerar el criterio físico basado en la subdensidad (Tabla 3), se observa que todas las configuraciones preservan una elevada proporción de regiones efectivamente subdensas, indicando que la identificación física de los vacíos se mantiene robusta aun cuando existan discrepancias geométricas.

Método	Modelo	0.50	0.80	0.85	0.90	0.95	0.99
<i>SVF Bounding Boxes</i>	MedSAM	0.958	0.969	0.972	0.977	0.983	0.992
<i>SVF Bounding Boxes</i>	SAM	0.993	0.994	0.994	0.995	0.995	0.996
<i>Sliding Windows</i>	MedSAM	0.647	0.667	0.678	0.695	0.710	0.741

Table 3. Métrica *Precision* evaluada bajo el criterio físico en función del umbral `segmentation_threshold` para los distintos métodos y modelos de segmentación.

En conjunto, el análisis de las métricas geométricas y físicas permite establecer configuraciones representativas para la evaluación final. En particular, el método de *Sliding Windows* con `segmentation_threshold=0.85` ofrece un compromiso adecuado entre cobertura y consistencia geométrica, mientras que el esquema *SVF Bounding Boxes* con MedSAM y `segmentation_threshold=0.50` favorece la recuperación de regiones subdensas dentro de las áreas delimitadas por las cajas, compensando parcialmente su naturaleza más restrictiva. Estas elecciones se utilizarán en la comparación final entre cosmologías.

8 Catálogo final de vacíos segmentados y validación global

Una vez fijada la configuración óptima a partir del análisis previo, el modelo aplicamos sobre la totalidad de las simulaciones consideradas con el objetivo

de evaluar su estabilidad frente a variaciones en el parámetro cosmológico Ω_m . Los catálogos obtenidos mediante los métodos *SVF Bounding Boxes* y *Sliding Windows* comparamos sistemáticamente con sus correspondientes catálogos de referencia generados con *Sparkling*, aplicando en todos los casos un criterio de filtrado basado en el radio característico $R_{\text{shot}} = 2.07 \text{ Mpc } h^{-1}$ para garantizar la significancia física de las estructuras identificadas. Las propiedades estadísticas globales de los catálogos finales se presentan en la Tabla 4, donde se observa que *Sliding Windows* identifica aproximadamente un orden de magnitud más vacíos que *SVF Bounding Boxes*, mientras que este último mantiene valores promedio de densidad integrada más consistentes con vacíos físicamente definidos.

Catálogo	Ω_m	N_{voids}	v_{count}	R_{min}	$\bar{R}$	R_{max}	Δ_{min}	Δ	Δ_{max}
SVF_BB ₁	0.1	5608	5601	2.0718	3.0885	5.0083	-0.9733	-0.8339	1.1794
SVF_BB _f	0.3	51193	49759	2.0718	3.0728	5.9825	-0.9859	-0.7152	23.0678
SVF_BB ₅	0.5	83192	78213	2.0718	3.0654	6.2913	-0.9939	-0.6025	60.5235
SW ₁	0.1	151584	111209	2.0718	3.9915	12.3844	-0.9302	0.0927	339.6546
SW _f	0.3	161184	108725	2.0718	3.8864	11.8789	-0.9717	0.2469	100.0735
SW ₅	0.5	166983	106994	2.0718	3.8101	10.6592	-0.9659	0.3433	137.8076

Table 4. Estadística descriptiva de los catálogos *SVF_BB_1*, *SVF_BB_f*, *SVF_BB_5*, *SW_1*, *SW_f* y *SW_5*. Los radios están expresados en $\text{Mpc } h^{-1}$.




Fig. 6. Comparación de la Función de Tamaño de Vacíos (VSF) obtenida por los métodos *SVF Bounding Boxes* y *Sliding Windows* frente a la simulación original, para distintos valores de Ω_m (0.1, 0.3 y 0.5).

Estas diferencias impactan directamente en la distribución de tamaños de los vacíos, como se observa en la VSF mostrada en la Figura 6. El método *SVF Bounding Boxes* reproduce la tendencia esperada con Ω_m , en concordancia con los catálogos de referencia, mientras que *Sliding Windows* muestra un comportamiento opuesto para los radios grandes, pero no tan marcado. Si comparamos directamente los métodos, *SVF Bounding Boxes* presenta una menor abundancia de vacíos en todos los rangos de radio y un corte más abrupto en radios intermedios, mientras que *Sliding Windows* incrementa la detección de vacíos medianos y grandes, lo que refleja su carácter exploratorio.

Finalmente, la relación entre el radio efectivo R_v y el contraste de densidad integrada Δ_v , presentada en la Figura 7, permite analizar las propiedades estructurales de las regiones identificadas. Aunque ambos métodos muestran una distribución más continua que la simulación de referencia, las predicciones permanecen concentradas en regímenes de baja densidad incluso al variar Ω_m , evidenciando que las segmentaciones preservan la identificación de regiones subdensas a pesar de la dispersión observada en los parámetros geométricos.




Fig. 7. Distribución conjunta del radio efectivo (R_v) y el contraste de densidad integrada (Δ_v) para la *Sparkling_Sim* (izquierda) y los catálogos predictivos de *SVF Bounding Boxes* (centro) y *Sliding Windows* (derecha).

9 Conclusiones y Trabajo a Futuro

En términos generales, los resultados obtenidos muestran que la aplicación de modelos de segmentación para la detección de vacíos cósmicos es viable, aunque presenta limitaciones relevantes asociadas a su falta de adaptación al dominio cosmológico. El enfoque tomográfico permite reutilizar arquitecturas preentrenadas sin modificaciones estructurales, pero evidencia diferencias marcadas entre modelos y estrategias de segmentación. En particular, el método *Sliding Window* solo resultó efectivo con MedSAM, mientras que SAM tendió a producir máscaras globales no informativas, lo que sugiere una ventaja del *fine-tuning* en datos con características similares a las de los campos de densidad.

Por otro lado, el método *SVF Bounding Boxes* mostró un desempeño más estable en ambos modelos, aunque dependiente de la información geométrica provista por SVF, lo que lo posiciona más como una herramienta de refinamiento que como un detector independiente. En ambos casos, los resultados indican sensibilidad a parámetros cosmológicos como Ω_m , aunque con comportamientos no completamente consistentes entre métodos, lo que refuerza la necesidad de un entrenamiento específico al dominio para capturar mejor las dependencias físicas subyacentes.

A pesar de estas limitaciones, la segmentación de instancias ofrece ventajas frente a métodos tradicionales al no imponer restricciones geométricas fuertes y

permitir la detección de morfologías irregulares, con potencial de escalabilidad en grandes volúmenes de datos.

Reconocimientos. A Este trabajo utilizó recursos computacionales de UNC Supercómputo (CCAD) de la Universidad Nacional de Córdoba ⁷, que forman parte del Sistema Nacional de Computación de Alto Desempeño (SNCAD) de la República Argentina.

References

- Alfaro, I. G., Rodriguez, F., Ruiz, A. N., & Lambas, D. G. (2020). How galaxies populate haloes in very low-density environments-an analysis of the halo occupation distribution in cosmic voids. *Astronomy & Astrophysics*, 638, A60.
- Colberg, J. M., Sheth, R. K., Diaferio, A., Gao, L., & Yoshida, N. (2005). Voids in a Λ cdm universe. *Monthly Notices of the Royal Astronomical Society*, 360(1), 216–226.
- Correa, C. M. (2021). *Vacíos cósmicos como laboratorios cosmológicos* [Doctoral dissertation, Universidad Nacional de Córdoba (UNC)].
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., Lo, W.-Y., et al. (2023). Segment anything. *Proceedings of the IEEE/CVF international conference on computer vision*, 4015–4026.
- Ma, J., He, Y., Li, F., Han, L., You, C., & Wang, B. (2024). Segment anything in medical images. *Nature Communications*, 15(1), 654.
- Neyrinck, M. C. (2008). Zobov: A parameter-free void-finding algorithm. *Monthly notices of the royal astronomical society*, 386(4), 2101–2109.
- Padilla, N. D., Ceccarelli, L., & Lambas, D. (2005). Spatial and dynamical properties of voids in a Λ cold dark matter universe. *Monthly Notices of the Royal Astronomical Society*, 363(3), 977–990.
- Paz, D. J., Correa, C. M., Gualpa, S. R., Ruiz, A. N., Bederián, C. S., Graña, R. D., & Padilla, N. D. (2023). Guess the cheese flavour by the size of its holes: A cosmological test using the abundance of popcorn voids. *Monthly Notices of the Royal Astronomical Society*, 522(2), 2553–2569.
- Planck Collaboration: Aghanim, N., et al. (2020). Planck 2018 results. vi. cosmological parameters. *Astron. Astrophys*, 641, A6.
- Ruiz, A. N., Paz, D. J., Lares, M., Luparello, H. E., Ceccarelli, L., & Lambas, D. G. (2015). Clues on void evolution—iii. structure and dynamics in void shells. *Monthly Notices of the Royal Astronomical Society*, 448(2), 1471–1482.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427–437.

⁷ <https://supercomputo.unc.edu.ar>