


Simulated Skewed Gaussian Splatting: nuevo enfoque de primitivas geométricas de mayor fidelidad visual

Simulated Skewed Gaussian Splatting: a new approach to geometric primitives for better visual fidelity

Leonardo Artilles Montero¹, Edián Broche Castro^{2*}, Ariel González Gómez³, Alex Samuel Bas Beovides⁴

Resumen El objetivo es mostrar que la aplicación tradicional del *gaussian splatting* se puede mejorar mediante la introducción de parámetros adicionales para lograr nuevas formas, mejorando así los resultados de la reconstrucción. Específicamente, se investiga el impacto de incorporar la asimetría (*skewness*), que permite a las gaussianas adoptar una gama más amplia de formas. Se realizaron evaluaciones experimentales sobre manchas gaussianas 2D para evaluar la efectividad de este enfoque. Los resultados indican que las gaussianas con asimetría proporcionan un rendimiento superior en varias métricas. Además, se ha desarrollado un método novedoso para simular la asimetría, sin requerir cambios en las técnicas de rasterización existentes. Este enfoque garantiza la compatibilidad y la facilidad de integración con los sistemas actuales, permitiendo su aplicación en 3D. Los hallazgos sugieren que la adición del parámetro de asimetría es una mejora valiosa y ofrece un potencial para mejorar los resultados de la reconstrucción en contextos 2D y 3D.

Palabras Clave: asimetría, gaussian splatting, síntesis de vistas nuevas.

Abstract *The aim is to show that the traditional application of gaussian splatting can be improved by introducing additional parameters to achieve new shapes, thereby enhancing reconstruction results. Specifically, the impact of incorporating skewness, which allows gaussians to adopt a wider range of shapes, is investigated. Experimental evaluations were performed on 2D gaussian splatters to assess the effectiveness of this approach. The results indicate that skewed gaussians provide superior performance across several metrics. Furthermore, a novel method for simulating skewness has been developed without requiring changes to existing rasterization techniques. This approach ensures compatibility and ease of integration with current systems, enabling its application in 3D. The findings suggest that adding the skewness parameter is a valuable enhancement and offers potential for improving reconstruction results in both 2D and 3D contexts.*

Keywords: *skewness, gaussian splatting, novel view synthesis.*

Mathematics Subject Classification: 11, 11A07, 11A15, 11D04.

¹Facultad de Matemática y Computación, Universidad de La Habana, La Habana, Cuba. Email: leo16am@gmail.com.

²Facultad de Matemática y Computación, Universidad de La Habana, La Habana, Cuba. Email: edianbc@gmail.com.

³Facultad de Matemática y Computación, Universidad de La Habana, La Habana, Cuba. Email: lenin46ariel@gmail.com.

⁴Facultad de Matemática y Computación, Universidad de La Habana, La Habana, Cuba. Email: abasbeovides@gmail.com.

*Autor para Correspondencia (Corresponding Author)

Editado por (Edited by): Damian Valdés Santiago, Facultad de Matemática y Computación, Universidad de La Habana, La Habana, Cuba.

Citar como: Artilles Montero, L., Broche Castro, E. González Gómez, A., & Bas Beovides, A.S. (2025). *Simulated Skewed Gaussian Splatting: nuevo enfoque de primitivas geométricas de mayor fidelidad visual*. *Ciencias Matemáticas*, 39(1), 49–54. DOI: <https://doi.org/10.5281/zenodo.17502783>. Recuperado a partir de <https://revistas.uh.cu/rcm/article/view/11138>.

Introducción

La técnica de *gaussian splatting* (3DGS, por sus siglas en inglés) ha revolucionado recientemente el campo del renderizado y la reconstrucción tridimensional [3]. Este método representa escenas complejas mediante la superposición de distribuciones gaussianas tridimensionales anisotrópicas, logrando capturar detalles visuales y texturas realistas con alta fidelidad. Gracias a su capacidad para generar representaciones visualmente convincentes con tiempos de ejecución considerablemente inferiores a otras técnicas previas, se ha convertido en uno de los métodos más adoptados.

Sin embargo, a pesar de sus ventajas, el 3DGS presenta limitaciones fundamentales [3]. Una de las principales problemáticas radica en la naturaleza inherente de sus primitivas: al utilizar distribuciones gaussianas simétricas y continuas, las transiciones dentro de la escena tienden a ser suavizadas [4, 6]. Esta característica dificulta la representación precisa de bordes definidos y discontinuidades geométricas [4, 6, 1].

Esta incapacidad para modelar adecuadamente límites definidos provoca que, durante la optimización, las gaussianas tiendan a degenerar en formas altamente anisotrópicas, generando artefactos visuales conocidos como “agujas” [6]. Este comportamiento no solo degrada la calidad visual, sino que también compromete la precisión geométrica de la reconstrucción.

Para abordar estos desafíos, esta investigación propone un nuevo enfoque de las primitivas geométricas para una mayor fidelidad visual, llamado *simulated skewed gaussian splatting*, que es una modificación del método original. El objetivo es mejorar la calidad visual y la precisión geométrica mediante la introducción de parámetros que simulen asimetría en las primitivas geométricas. Este trabajo propone una extensión que incrementa la capacidad expresiva del modelo para representar discontinuidades, sin comprometer su eficiencia computacional ni la compatibilidad con investigaciones existentes.

Relevancia del estudio

Este trabajo aborda la dificultad del 3D Gaussian Splatting (3DGS) para representar bordes definidos. Se propone un método que simula asimetría en las primitivas gaussianas para mejorar la precisión geométrica. Los experimentos iniciales en 2D validan que este enfoque representa más fielmente gradientes complejos (luces, sombras) y discontinuidades, mostrando además una convergencia más rápida. Este aporte ofrece una vía potencial para incrementar la fidelidad visual del 3DGS, destacando por su compatibilidad con el *pipeline* de renderizado existente, beneficiando así futuras investigaciones en reconstrucción y renderizado 3D.

1. Gaussian splatting

El método fue propuesto por Kerbl et al. [3] y representa una escena tridimensional mediante un conjunto explícito de primitivas gaussianas anisotrópicas. Cada gaussiana g_i se caracteriza por un conjunto de parámetros optimizables:

- Posición (centro): $p_i \in \mathbb{R}^3$.
- Covarianza anisotrópica: $\Sigma_i \in \mathbb{R}^{3 \times 3}$, que determina su forma y orientación.
- Opacidad: α_i^{max} , un valor escalar que controla la transparencia.
- Color: representado mediante armónicos esféricos (SH, por sus siglas en inglés) para modelar efectos dependientes de la vista.

A diferencia de los métodos implícitos como NeRF [5], 3DGS utiliza un rasterizador diferenciable basado en *splatting* [3]. Cada gaussiana 3D se proyecta al plano de la imagen 2D, y las contribuciones de color de las gaussianas proyectadas (*splats*) se componen mediante *alpha blending* ordenado por profundidad para formar la imagen final.

La principal limitación de esta representación es que las primitivas gaussianas son funciones suaves con soporte infinito. Como consecuencia, actúan como filtros de paso-bajo, lo que dificulta intrínsecamente la representación de discontinuidades marcadas en geometría o color (bordes duros) sin introducir una gran cantidad de primitivas agrupadas en dichas regiones [6].

1.1 Modificaciones para la representación de discontinuidades

La dificultad del 3DGS para modelar bordes definidos ha impulsado múltiples investigaciones que buscan mejorar la expresividad de las primitivas [1, 6, 4]. Estas técnicas resaltan que, al modificar la rigidez y simetría de las gaussianas, es posible capturar con mayor precisión las discontinuidades abruptas de la escena.

El método 3D-HGS [4] aborda directamente el problema de la simetría. Reconoce que una distribución gaussiana completa no es ideal para modelar regiones cercanas a los bordes, ya que difumina la información por igual en todas direcciones. La solución que propone es el uso de medias gaussianas como primitivas. Estos *kernels* corresponden a una gaussiana cortada por un plano. De esta manera, la primitiva decae suavemente hacia el interior de un objeto, pero es truncada abruptamente en la dirección opuesta, coincidiendo con la superficie o el borde. Esto permite a 3D-HGS representar de forma nativa discontinuidades tanto de forma como de color, donde las gaussianas convencionales tienden a fallar.

DisC-GS [6] se enfoca en el mismo problema desde una perspectiva de optimización. Propone modificaciones en el *pipeline* para detectar y preservar activamente los bordes definidos. En esencia, DisC-GS permite que la contribución de un splat gaussiano pueda cortarse o limitarse de forma adaptativa. Si el algoritmo detecta que una gaussiana solapa regiones con profundidades significativamente diferentes (es decir, cruza un borde), ajusta su distribución para evitar una mezcla inadecuada entre ambos lados de la discontinuidad.

Tanto 3D-HGS como DisC-GS demuestran de forma consistente que el manejo explícito de las discontinuidades es fundamental para superar las limitaciones del 3DGS clásico. Estos trabajos confirman que la incorporación de mayor expresividad en la forma de las primitivas, ya sea mediante soporte asimétrico (3D-HGS) o mediante adaptación consciente de los bordes (DisC-GS), es clave para mejorar la fidelidad geométrica.

Sin embargo, estas soluciones pueden implicar alteraciones significativas en el *pipeline* original [3]. La solución que se propone a continuación se inspira en esta necesidad, buscando una solución que introduzca asimetría de forma eficiente y compatible con la estructura original.

2. Solución propuesta

La intuición detrás del enfoque presentado radica en la observación de que las curvas gaussianas unidimensionales no son óptimas para representar ciertas funciones. Por ejemplo, si se desea simular una función casi monótona, se necesita usar la suma de varias gaussianas. En dibujo y pintura, a menudo se utilizan gradientes para representar sombras o cambios en los objetos. Basado en esta idea, se propone que una curva gaussiana con asimetría puede representar mejor estos gradientes. Una curva con asimetría tendrá una cola que puede representar el gradiente.

Para validar el método se realizaron experimentos. Se propone la siguiente forma de simular la asimetría en 2D, que también es aplicable a 3D (Figura 1).

Para simular la asimetría se toma una mancha gaussiana (A) que actúa como base, se introduce otra gaussiana (B) que actúa como una máscara. Entonces se desea calcular la intersección ponderada de ambas gaussianas. Para ello, se desarrolló la siguiente fórmula:

$$A \cdot (1 - e^{-S \cdot B}), \quad (1)$$

donde S es un nuevo parámetro entrenable. Aunque esta fórmula no simula exactamente la asimetría, representa bien el objetivo que se quiere lograr. Además, como funciona multiplicando las proyecciones ya rasterizadas de dos gaussianas (en el caso 3D), no requiere muchos cambios en el algoritmo de rasterización 3D original.




Figura 1. En azul y verde las gaussianas A y B , respectivamente. Se observa cómo la gaussiana que se obtiene (en la intersección) presenta asimetría direccional y bordes duros [The gaussian A and B are shown in blue and green, respectively. Note how the resulting gaussian line (at the intersection) exhibits directional asymmetry and hard edges.].

Sin embargo, este método no es el más óptimo para simular gaussianas con asimetría, ya que requiere crear dos gaussianas, lo que es intensivo tanto en memoria como en tiempo. En teoría solo se necesita un parámetro por dimensión para crear asimetría de manera efectiva. No obstante, dado que el objetivo principal era probar la eficacia más que la eficiencia del enfoque, se implementó de esta manera. Trabajos futuros podrían explorar implementaciones más eficientes, mejorando potencialmente tanto el uso de memoria como la velocidad computacional.

3. Métricas de evaluación

Para cuantificar objetivamente el rendimiento del método propuesto (SGS) frente al GS, se emplearon las siguientes métricas estándar en la literatura de reconstrucción de imágenes:

Pérdida Final (Final Loss) Representa el valor de la función de objetivo (función de pérdida) al concluir el proceso de entrenamiento. Esta métrica cuantifica la discrepancia o error directo entre la imagen generada por el modelo y la imagen de referencia (*ground truth*), según el criterio de optimización definido [3]. El valor más bajo posible, donde 0 indicaría un ajuste perfecto a los datos de entrenamiento.

PSNR (Peak Signal-to-Noise Ratio) La relación señal-ruido (PSNR, por sus siglas en inglés) mide la calidad de la reconstrucción basándose en el error cuadrático medio

(MSE, por sus siglas en inglés) entre la imagen original y la reconstruida. Compara el valor máximo posible de la señal con la potencia del ruido (error) que la afecta. Se expresa en decibelios (dB) [2]. Un valor más alto indica una mejor calidad (menos ruido). Un PSNR infinito (∞ dB) correspondería a una reconstrucción idéntica a la original.

SSIM (Structural Similarity Index Measure) El índice de similitud estructural (SSIM, por sus siglas en inglés) es una métrica de percepción diseñada para alinearse mejor con el sistema visual humano [7]. En lugar de calcular errores absolutos píxel a píxel, SSIM evalúa la degradación de la calidad como un cambio percibido en la información estructural, comparando tres componentes: luminancia, contraste y estructura. El índice varía entre -1 y 1 . Un valor de 1 indica una similitud estructural perfecta.

4. Experimentos

Se aplicó el código a varias imágenes usando un pequeño número de manchas para observar si la hipótesis propuesta de que la asimetría podría representar mejor gradientes como luces y sombras. Como se observa en la Figura 2, en varios puntos de la imagen, las manchas se desviaron para representar sombras de manera efectiva. Esto fue particularmente evidente en regiones con iluminación y sombreado complejos, donde las gaussianas asimétricas se adaptaron más naturalmente a las variaciones de luz y sombra.




Figura 2. Ejemplos de gaussianas con asimetría en imágenes entrenadas [*Examples of gaussian curves with asymmetry in trained images*].

Como se muestra en la Figura 3 se comparó el *gaussian*

splatting clásico (GS) con el enfoque mejorado con asimetría (SGS), ambos utilizando un número fijo de 200 manchas (sin densificación) a lo largo de 2000 iteraciones. El método propuesto demostró una mayor fidelidad en detalles intrincados, especialmente en regiones de la imagen que presentaban ángulos rectos o formas complejas, sin caer en artefactos alargados. Esta mejora fue evidente en los bordes de los comics y en la vestimenta de los personajes. Además, este enfoque exhibió una tasa de convergencia más rápida de la función de pérdida, lo que indicó una dinámica de entrenamiento más eficiente en comparación con el método clásico.

Tras estas observaciones iniciales, se realizó una evaluación sistemática sobre cuatro imágenes de prueba. Se evaluaron dos métricas principales: PSNR y SSIM [7].

Los experimentos se ejecutaron en una Laptop con un i7 con 16 GB de RAM y una GPU RTX 2080 Super-MaxQ de 8GB. Se usaron dos configuraciones diferentes: una con 100 gaussianas y otra con 500 gaussianas, comparando en ambos casos el GS con el método SG (tablas 1–6).

Tabla 1. Comparación de Loss Final con 100 gaussianas [*Final Loss Comparison with 100 Gaussians*].

Imagen	GS	SGS	Mejora
kodim	0,1201	0,1165	3,00 %
lenna	0,1008	0,0897	11,01 %
parrots	0,0771	0,0770	0,13 %
yodas	0,1072	0,1038	3,17 %

Tabla 2. Comparación de PSNR con 100 gaussianas [*PSNR Comparison with 100 Gaussians*].

Imagen	GS	SGS	Diferencia
kodim	20,0205	20,3310	+0,3105 dB
lenna	18,7849	19,5890	+0,8041 dB
parrots	20,2646	19,5284	-0,7362 dB
yodas	19,0714	18,8311	-0,2403 dB

Tabla 3. Comparación de SSIM con 100 gaussianas [*SSIM Comparison with 100 Gaussians*].

Imagen	GS	SGS	Diferencia
kodim	0,3491	0,3653	+0,0162
lenna	0,5572	0,5995	+0,0423
parrots	0,5939	0,6029	+0,0090
yodas	0,5013	0,5162	+0,0149

5. Discusión

Los resultados cuantitativos obtenidos en la evaluación en 2D, resumidos en las Tablas 1 a 6, sugieren que el enfoque




Figura 3. Comparación entre el método propuesto (derecha abajo) y el *gaussian splatting* clásico en 2D (izquierda abajo) [Comparison between the proposed method (bottom right) and classical 2D gaussian splatting (bottom left)].

Tabla 4. Comparación de Loss Final con 500 gaussianas [Final Loss Comparison with 500 Gaussians].

Imagen	GS	SGS	Mejora
kodim	0,1006	0,1041	-3,49 %
lenna	0,0715	0,0690	+3,50 %
parrots	0,0617	0,0675	-9,40 %
yodas	0,0876	0,0841	+3,99 %

Tabla 5. Comparación de PSNR con 500 gaussianas [PSNR Comparison with 500 Gaussians].

Imagen	GS	SGS	Diferencia
kodim	21,5359	21,3481	-0,1878 dB
lenna	21,3612	21,8135	+0,4523 dB
parrots	21,5226	21,0369	-0,4857 dB
yodas	20,4078	20,6926	+0,2848 dB

Tabla 6. Comparación de SSIM con 500 gaussianas [SSIM Comparison with 500 Gaussians].

Imagen	GS	SGS	Diferencia
kodim	0,4486	0,4196	-0,0290
lenna	0,6815	0,6885	+0,0070
parrots	0,6796	0,6465	-0,0331
yodas	0,5880	0,5969	+0,0089

SGS presenta un potencial notable, aunque con un rendimiento que se manifiesta de manera variable según la configuración y la imagen.

En el escenario con un número limitado de primitivas (100 gaussianas), SGS superó consistentemente al GS clásico en la métrica SSIM (Tabla 3), lo que apunta a una mejor fidelidad estructural percibida al representar gradientes y detalles complejos con menos recursos. Este patrón de mejora en la Pérdida Final y SSIM se observó en la mayoría de los casos, a pesar de que la ganancia en PSNR fue menos consistente y mostró valores inferiores en un par de imágenes.

Por otro lado, en la configuración con un mayor número de primitivas (500 gaussianas), el margen de mejora de SGS se hizo menos evidente, e incluso se observaron reducciones en el rendimiento en algunas imágenes específicas al compararlo con el GS clásico. Este resultado mixto sugiere que, si bien el concepto de asimetría es prometedor para mejorar la expresividad de las primitivas, la implementación actual podría no ser universalmente superior al GS clásico, especialmente en configuraciones densas, y requiere optimización adicional para maximizar su potencial.

Los experimentos realizados validan la hipótesis de que la incorporación de asimetría en GS mejora la representación de gradientes y características complejas de las imágenes. Al introducir asimetría, este método captura de manera efectiva variaciones sutiles en la iluminación y el sombreado con menos manchas, reduciendo el costo computacional y de memoria asociado al GS, que depende de múltiples manchas superpuestas para lograr efectos similares.

Sin embargo, la implementación actual requiere la generación de dos gaussianas para simular la asimetría, lo que duplica el costo computacional. Si bien este enfoque resultó efectivo para los experimentos iniciales, optimizar la simulación de la asimetría para que requiera menos parámetros sigue siendo un desafío pendiente. Además, aunque este método muestra promesas en experimentos en 2D, extender y validar su eficacia en escenarios 3D será esencial para su aplicabilidad.

Conclusiones y trabajo futuro

Se presentó una mejora para el Gaussian Splatting al introducir la asimetría en las manchas gaussianas. Esta mejora permite una representación más flexible y precisa de gradientes y características complejas de las imágenes, abordando las limitaciones de las curvas gaussianas tradicionales, que a menudo requieren múltiples manchas para simular funciones casi monótonas o gradientes. Los resultados experimentales en 2D demuestran que las gaussianas asimétricas logran una mayor fidelidad en la reconstrucción de regiones detalladas e intrincadas de las imágenes, al mismo tiempo que ofrecen

una convergencia más rápida durante el entrenamiento.

Quedan varias áreas por explorar:

- Desarrollar un método más eficiente para simular la asimetría utilizando un solo parámetro por dimensión podría reducir el costo computacional y de memoria, haciendo que el enfoque sea escalable.
- Extender el método mejorado con asimetría al GS 3D, lo que implicaría adaptar los parámetros de asimetría a tres dimensiones y evaluar el rendimiento del método para la reconstrucción 3D.
- Realizar un extenso *benchmarking* frente a otras técnicas de reconstrucción en conjuntos de datos diversos.

Suplementos

Este artículo no contiene información suplementaria.

Conflictos de interés

Se declara que no existen conflictos de interés.

Contribución de autoría

Conceptualización L.A.M., E.B.C., A.G.G., A.B.B.

Administración del proyecto L.A.M.

Curación de datos L.A.M.

Análisis formal L.A.M., A.G.G., A.B.B.

Software L.A.M., E.B.C.

Investigación L.A.M., E.B.C.

Metodología L.A.M., E.B.C.

Validación L.A.M., E.B.C.

Visualización L.A.M.

Supervisión L.A.M., E.B.C.

Redacción: preparación del borrador original L.A.M., E.B.C.

Redacción: revisión y edición A.G.G., A.B.B.

Referencias

- [1] Held, J., R. Vandeghen, A. Hamdi, A. Deliege, A. Cioppa, S. Giancola, A. Vedaldi, B. Ghanem, and M. Van Droogenbroeck: *3D Convex Splatting: Radiance Field Rendering with 3D Smooth Convexes*. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 21360–21369, June 2025. https://openaccess.thecvf.com/content/CVPR2025/papers/Held_3D_Conv

[ex_Splatting_Radiance_Field_Rendering_with_3D_Smooth_Convexes_CVPR_2025_paper.pdf](#).

- [2] Huynh-Thu, Q. and M. Ghanbari: *Scope of validity of PSNR in image/video quality assessment*. *Electronics Letters*, 44(13):800–801, 2008. <https://doi.org/10.1049/el:20080522>.
- [3] Kerbl, B., G. Kopanas, T. Leimkühler, and G. Drettakis: *3D Gaussian Splatting for Real-Time Radiance Field Rendering*. *ACM Transactions on Graphics*, 42(4):1–14, 2023. <https://doi.org/10.1145/359243>.
- [4] Li, H., J. Liu, M. Sznaiier, and O. Camps: *3D-HGS: 3D Half-Gaussian Splatting*. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 10996–11005, June 2025. <https://doi.org/10.1109/CVPR52734.2025.01027>.
- [5] Mildenhall, B., P.P. Srinivasan, M. Tancik, J.T. Barron, R. Ramamoorthi, and R. Ng: *NeRF: Representing scenes as neural radiance fields for view synthesis*. *Communications of the ACM*, 65(1):99–106, 2021. <https://doi.org/10.1145/3503250>.
- [6] Qu, H., Z. Li, H. Rahmani, Y. Cai, and J. Liu: *DisCGS: Discontinuity-aware Gaussian Splatting*. In Glocker, A., L. Mackey, D. Belgrave, A. Fan, U. Paquet, J. Tomczak, and C. Zhang (editors): *Advances in Neural Information Processing Systems*, volume 37, pages 112284–112309. Curran Associates, Inc., 2024. https://proceedings.neurips.cc/paper_files/paper/2024/file/cbc80272426028bd561f3889af65c704-Paper-Conference.pdf.
- [7] Wang, Z., A.C. Bovik, H.R. Sheikh, and E.P. Simoncelli: *Image quality assessment: from error visibility to structural similarity*. *IEEE Transactions on Image Processing*, 13(4):600–612, 2004. <https://doi.org/10.1109/TIP.2003.819861>.

