

El impacto de la integración de canales guía basados en la predominancia colorimétrica y naturalidad de escena en imágenes laparoscópicas

The Impact of Integrating Guidance Channels Based on Colorimetric Predominance and Scene Naturalness in Laparoscopic Images

Diana Jazmín Torres López¹, Ángel Roberto Flores Delgado⁵, Sebastián Salazar Colores¹, Alfonso Ramírez Pedraza²,
Edgard Efrén Lozada Hernández³, Rocío Alfonsina Lizarraga Morales⁴

¹Centro de Investigaciones en Óptica A.C.
dianatl@cio.mx, sebastian.salazar@cio.mx

²Centro de Investigación en Ciencias Aplicadas y Tecnología Avanzada del Instituto Politécnico Nacional, CP. 76090, Santiago de Querétaro, Querétaro.

aramirez_ixm@ipn.mx

³Hospital Regional de Alta Especialidad del Bajío (HRAEB), CP. 37544, León, Guanajuato, México.

edgardlozada2@gmail.com

⁴División de Ingenierías, Campus Irapuato-Salamanca, Universidad de Guanajuato, CP. 36787, Salamanca, Guanajuato, México.

ra.lizarragamorales@ugto.mx

⁵División de Ciencias e Ingenierías, Campus León, Universidad de Guanajuato, CP. 37150, León, Guanajuato, México.

ar.floresdelgado@ugto.mx

Resumen

La presencia de humo en laparoscopia por corte y coagulación de tejido dificulta ver bien el campo de operación: baja el contraste, esconde bordes y ocurren cambios en el color. Proponemos usar un canal guía de entropía local, que genera un mapa a partir de la imagen para indicar en qué zonas conviene despejar más y en cuáles menos, evitando borrar detalle y cambios fuertes de color. Cuando el humo afecta la textura, la entropía baja. La intención de este canal guía es detectar esas áreas y ayudar a recuperar textura y bordes. Funciona como información extra que el modelo usa de forma automática. El resultado es una eliminación de humo más selectivo: actúa con fuerza donde hay humo denso y es cuidadoso donde el tejido ya está claro.

Palabras clave: Inteligencia artificial; Entropía; Laparoscopia; Colectectomía; Redes Generativas Adversarias.

Introducción

La cirugía laparoscópica (Figura 1) es una técnica quirúrgica que consiste en la visualización y el tratamiento del interior de la cavidad abdominal y/o pélvica mediante pequeñas incisiones (normalmente de 0.5-1.5 cm), la insuflación de CO₂ para distender el abdomen, y el uso de un instrumento óptico (laparoscopio) junto con herramientas especializadas, evitando una incisión abdominal amplia (Powell & Khaund, 2016).



Figura 1. Cirugía laparoscópica.

Fuente: Imagen obtenida del sitio web <https://www.topdoctors.es/articulos-medicos/cirugia-laparoscopica-en-ginecologia-la-alternativa-menos-invasiva/>

La presencia de humo quirúrgico en la cirugía laparoscópica degrada de manera importante la visibilidad de los órganos y tejidos, lo cual puede prolongar el tiempo operatorio e incrementar la probabilidad de errores del cirujano. Estudios clínicos han demostrado que mantener una imagen laparoscópica clara mediante métodos de eliminación de niebla digital puede acortar la duración de la intervención y reducir la ansiedad del cirujano (Gu *et al.*, 2015). Tradicionalmente, se emplean dispositivos de evacuación de humo (por ejemplo, trocares con filtros) para mejorar la visibilidad, pero tales soluciones físicas resultan costosas o impracticables en muchos entornos (Salazar-Colores *et al.*, 2020). Por ello, existe un creciente interés en soluciones basadas en procesamiento de imágenes y visión por computadora para la eliminación digital del humo quirúrgico. No obstante, el desarrollo de algoritmos efectivos se ha visto limitado por la escasez de datos laparoscópicos disponibles públicamente; en particular, la ausencia de conjuntos de imágenes emparejadas reales (en este caso imágenes con y sin humo en el mismo instante) ha obligado a trabajar con datos sintéticos, los cuales pueden llegar a presentar limitaciones a la hora de capturar completamente la complejidad de las escenas in vivo, sin embargo, siguen siendo uno de los principales tipos de datos de entrenamiento empleados en el área de inteligencia artificial (Xia *et al.*, 2024).

Diversos enfoques de mejora de imagen se han propuesto para abordar el problema de eliminación de humo en laparoscopia. Métodos clásicos basados en procesamiento digital incluyen filtrados por inferencia Bayesiana, mejora de contraste y técnicas inspiradas en eliminación de niebla atmosférica (Baid *et al.*, 2017; Kotwal *et al.*, 2016). Por ejemplo, se han adaptado modelos físicos como el de dispersión atmosférica junto con el uso de principios de imagen: el dark channel prior (principio de canal oscuro) y principios cromáticos han sido empleados para estimar la transmisión de luz en escenas laparoscópicas con humo (Salazar-Colores *et al.*, 2020) así como módulos de segmentación (Moreno *et al.*, 2024). Sin embargo, debido a la naturaleza compleja y dinámica del humo quirúrgico, estos métodos tradicionales pueden llegar a producir resultados inconsistentes, introduciendo artefactos de color o saturando la imagen en zonas sin humo (Wu *et al.*, 2025). Lograr eliminar el humo sin alterar la apariencia natural del tejido es una tarea compleja; de hecho, muchos de estos enfoques tienden a degradar o desbalancear la coloración original en las regiones libres de humo. En años recientes se han explorado soluciones basadas en inteligencia artificial, las cuales han mostrado resultados prometedores en tareas como la eliminación de humo de imágenes médicas (Chen *et al.*, 2022; Pan *et al.*, 2022; Wu *et al.*, 2025).

Los trabajos recientes implementan redes neuronales convolucionales profundas y modelos generativos adversariales (GAN) para traducir imágenes con humo en imágenes limpias. Algunos abordan el problema de forma no supervisada mediante traducción de dominios (por ejemplo, con arquitecturas tipo CycleGAN) para evitar la dependencia de datos emparejados (Vishal *et al.*, 2019). Entre el estado del arte actual, destaca el uso de canales guía o máscaras de atención integradas en la red, que aportan información adicional sobre la escena. Un ejemplo notable también es el método de Salazar-Colores *et al.* (2020), quienes propusieron un cGAN condicional con un canal oscuro integrado como máscara guía. Este canal oscuro actúa como mapa de concentración de humo, proporcionando a la red indicios sobre las regiones que requieren mayor restauración. Gracias a esta guía adicional, su modelo logra eliminar el humo local presente mientras recupera colores de tejido realistas.

De manera similar, otros autores han reportado que incorporar mapas significativos (por ejemplo, módulos de atención o relevantes) como canales adicionales en las entradas de la red mejora el rendimiento en tareas de visión computacional médica (Murabito *et al.*, 2018). En particular, integrar información guiada permite a la red enfocarse en rasgos relevantes de la imagen, contribuyendo a un procesamiento más robusto y específico del problema de humo.

Siguiendo esta línea, el presente trabajo explora el impacto de integrar canales guía basados en la predominancia colorimétrica y la naturalidad de la escena dentro de una arquitectura GAN para imágenes laparoscópicas con humo. Concretamente, se propone sustituir el canal oscuro por un canal de entropía local como cuarto canal de entrada (configuración RGB-E). La entropía de imagen se emplea aquí como mapa de complejidad local con el fin de distinguir regiones de humo frente a tejido: en general, las regiones afectadas por humo denso exhiben baja entropía (poca variabilidad de intensidad), mientras que las áreas de tejido con texturas ricas presentan entropía más alta (Kim, 2021). Por ello, al concatenar el mapa de entropía junto con los tres canales de color originales, se proporciona a la red una señal adicional que resalta las zonas de bajo detalle (humo) frente a las de alto detalle (estructura anatómica). Antes de la integración, el mapa de entropía obtenido de la imagen en escala de grises se normaliza y se refina mediante un filtro guiado utilizando la propia imagen como guía, con el objetivo de suavizar el ruido sin perder bordes significativos. De esta forma,



el canal guía de entropía mantiene la continuidad de las estructuras anatómicas a la vez que enfatiza las diferencias locales debidas al humo. En resumen, la incorporación de este cuarto canal informativo busca equilibrar la eliminación de humo con la conservación de la apariencia natural de la escena quirúrgica, ayudando al modelo a suprimir el efecto del humo sin afectar la coloración del tejido ni difuminar bordes relevantes. Este enfoque, denominado GANtropy, se apoya en el aprendizaje profundo para mejorar la visibilidad laparoscópica, proporcionando al modelo indicios explícitos sobre dónde y cuánto corregir la imagen, contribuyendo así a un campo visual más claro y realista durante la cirugía.

La evaluación de los resultados obtenidos del procesamiento de imágenes mediante modelos de aprendizaje profundo se realiza tanto de forma cualitativa (a través de la inspección visual) como cuantitativa (mediante métricas objetivas). La elección de las métricas depende de si la evaluación se lleva a cabo con imágenes emparejadas o no emparejadas.

Las imágenes emparejadas son aquellas que presentan una correspondencia directa entre la imagen de entrada y su versión procesada o de referencia, permitiendo comparar píxel a píxel ambos resultados. Por el contrario, las imágenes no emparejadas no tienen una correspondencia exacta, sino que pertenecen a conjuntos diferentes, pero relacionados, lo que requiere el uso de métricas sin referencia para estimar la calidad visual.

En el caso de imágenes emparejadas, es común utilizar las métricas como PSNR (Peak Signal-to-Noise Ratio o Relación Pico Señal-Ruido) y SSIM (Structural Similarity Index Metric o Índice de Similitud Estructural).

Para imágenes no emparejadas, especialmente en áreas como la eliminación de humo o niebla, se emplean métricas sin referencia como FADE (Fog Aware Density Estimator o Estimador de Densidad de Niebla), NIQE (Natural Image Quality Evaluator o Evaluador de Calidad de Imagen Natural) y BRISQUE (Blind/Referenceless Image Spatial Quality Evaluator o Evaluador de Calidad Espacial de Imágenes sin Referencia).

Cada una de las métricas evalúan aspectos diferentes en las imágenes:

PSNR: mide la fidelidad entre la imagen procesada y la original; valores más altos indican menor distorsión y, por tanto, mejor calidad (Horé & Ziou, 2010).

SSIM: evalúa la similitud estructural considerando luminancia, contraste y estructura; representa de manera más fiel la percepción visual humana que el PSNR (Horé & Ziou, 2010; Nilsson & Akenine-Möller, 2020).

FADE: estima la densidad de niebla o humo residual en una imagen; valores menores reflejan una eliminación más efectiva (Lark Kwon Choi *et al.*, 2015).

NIQE: evalúa la calidad perceptual sin requerir una imagen de referencia, basándose en estadísticas naturales; valores más bajos indican mayor calidad visual (Mittal *et al.*, 2013).

BRISQUE: mide la calidad espacial de la imagen a partir de características naturales y sin referencia; valores más bajos corresponden a una mejor calidad percibida (Mittal *et al.*, 2012).

Metodología Propuesta

Preparación de datos de entrenamiento

Para el entrenamiento se utilizó una base de datos sintética propia, obtenida con base en la información proporcionada por el HRAEB bajo el oficio de autorización: CI/HRAEB/005/2021. La base de datos consistió en 20,000 pares de imágenes sintéticas (imágenes libres de humo naturales y con simulado con Blender) laparoscópicas de colecistectomía emparejadas.



Infraestructura

El entrenamiento fue realizado en una estación de trabajo equipada con una GPU NVIDIA Quadro RTX A4000 (16 GB VRAM) ejecutando el sistema operativo Pop! OS 22.04 en un entorno con Python 3.10, PyTorch 1.13.0 con las demás librerías indicadas por los autores de la red base (Salazar-Colores *et al.*, 2020).

Entrenamiento

El entrenamiento fue realizado con base en una red especializada en la eliminación de humo en imágenes laparoscópicas reportada en el estado del arte, dicha red consiste en una red cGAN tipo pix2pix guiada por un cuarto canal (canal oscuro) (Salazar-Colores *et al.*, 2020). Los parámetros e hiperparámetros propuestos por los autores se mantuvieron sin cambios, con el fin de permitir una comparación justa con nuestra propuesta, que consiste en sustituir el cuarto canal original por un mapa de complejidad local, llamado más adelante como canal de entropía.

Canal de entropía: Desmoke GANtropy

Un canal de entropía fue incorporado como un cuarto componente de entrada en la red base, funcionando como un mapa de complejidad local destinado a diferenciar zonas con humo (caracterizadas por baja entropía) de aquellas correspondientes a tejido (alta entropía). De esta manera, la red recibió información de tipo RGBE, integrando el canal de entropía junto con los tres canales de color originales.

La entropía local se calculó a partir de la versión en escala de grises de cada imagen, considerando vecindarios de forma circular alrededor de cada píxel. Para un píxel (x) y su vecindario $N_r(x)$, la entropía se define como:

$$H(x) = - \sum_i p_i(x) \log_2(p_i(x)). \quad (1)$$

Donde ($p_i(x)$) representa la probabilidad de aparición del nivel de intensidad (i) dentro del vecindario $N_r(x)$. Este parámetro ofrece una medida de la variabilidad local: las regiones con mayor desorden o texturas más complejas presentan valores altos de entropía, mientras que las zonas uniformes tienden a mostrar valores bajos.

Una vez generado el mapa de entropía, se aplicó una normalización min-max para ajustar los valores al intervalo $([0, 1])$. Posteriormente, el mapa fue suavizado mediante un filtro guiado, utilizando la propia imagen en escala de grises como referencia. Este proceso permitió reducir el ruido y conservar la continuidad de los bordes anatómicos, resultando en un canal de entropía más estable y visualmente coherente con la estructura original de la escena.

Finalmente, el mapa refinado se concatenó con los tres canales RGB de la imagen, conformando las representaciones RGBE utilizadas en el experimento denominado GANtropy o RGBE (Figura 2). Esta integración aportó al modelo información adicional sobre la distribución espacial y la complejidad local de las intensidades, favoreciendo una mejor caracterización de las regiones afectadas por humo y de los detalles anatómicos durante las fases de entrenamiento e inferencia.



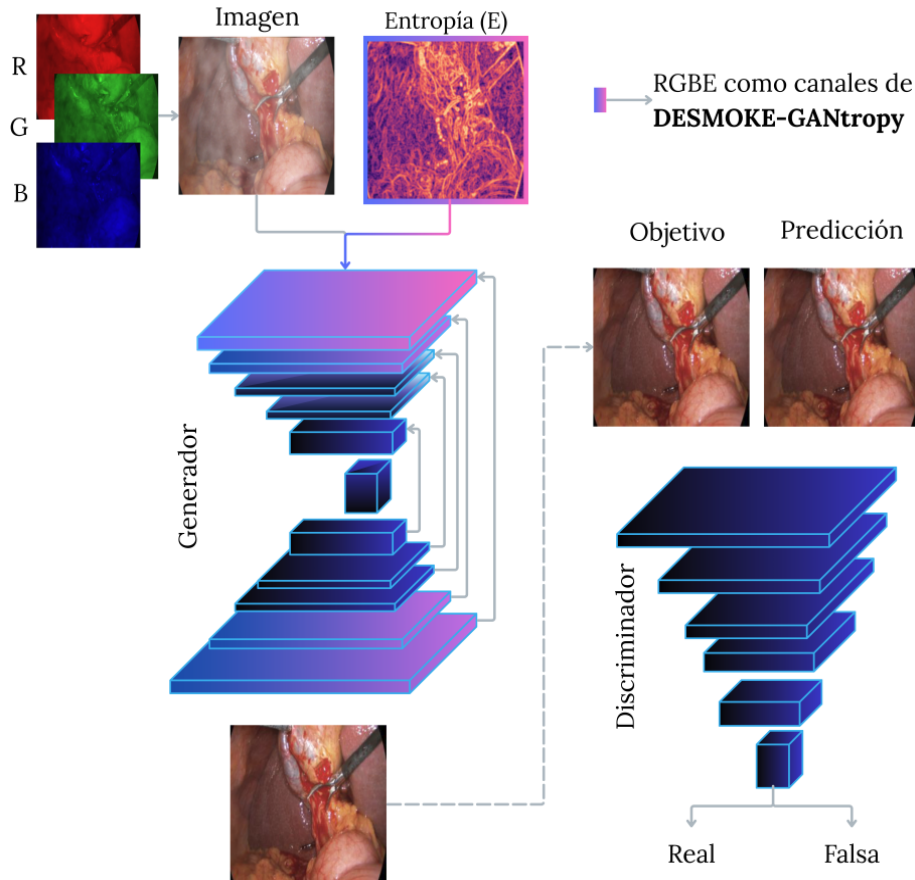


Figura 2. Propuesta de red DESMOKE-GANtropy.
Fuente: Autoría propia.

Estudio de generalización

El estudio de generalización se realizó con 1000 imágenes provenientes de bases de datos emparejadas y no emparejadas reportadas en el estado del arte (Pan *et al.*, 2022; Xia *et al.*, 2024) así como con nuestra propia base de datos. Para inferencias sobre datos propios no emparejados se tomaron 1000 imágenes con humo natural de la base de datos propia, las cuales no fueron parte del entrenamiento.

Las métricas evaluadas para datos emparejados fueron PSNR (Horé & Ziou, 2010) y SSIM (Wang *et al.*, 2004), mientras que para no emparejados fueron FADE (Lark Kwon Choi *et al.*, 2015), NIQE (Mittal *et al.*, 2013) y BRISQUE (Mittal *et al.*, 2012). Todas las métricas fueron calculadas en base al código o formulas correspondiente a los autores a fin de garantizar reproducibilidad.

Resultados

Cualitativos

Cualitativamente, podemos observar en la Figura 3 que ambos modelos, el modelo base con sus canales originales y el modelo propuesto, presentan resultados muy similares. Sin embargo, es importante recordar que, en este tipo de restauración de imágenes médicas, no solo interesa el grado de restauración logrado,

sino también la manera en que se ha realizado dicha restauración. Mantener un equilibrio entre el nivel de mejora de la imagen y la conservación natural de los colores de la escena también es un aspecto importante a considerar en los resultados obtenidos.

En este sentido, puede apreciarse que el modelo base tiende a saturar los colores en zonas anatómicas de importancia, además de conservar aún un nivel de humo perceptible. Esta diferencia se hace más evidente al comparar los resultados del modelo base con los obtenidos por GANtropy en los mosaicos 1, 4 y 5, donde el modelo propuesto logra eliminar el humo sin saturar la coloración natural de las zonas anatómicas en escena.




Figura 3. Resultados cualitativos de inferencias con 1000 muestras de base de datos propia. Salazar-Colores et al., 2020 es el modelo base. Fuente: Autoría propia.

Para analizar la capacidad de generalización de nuestro modelo, se evaluó su rendimiento utilizando bases de datos reportadas en el estado del arte. La Figura 4 muestra cinco muestras provenientes de la base de datos de Xia *et al.*, 2024. En este caso, se observan resultados similares entre ambos modelos; sin embargo, existen diferencias que permiten distinguir su desempeño. En el mosaico 3, por ejemplo, el modelo base logra una mayor eliminación del humo en comparación con GANtropy; no obstante, se aprecia la presencia de ruido y colores no naturales en la escena (especialmente en la esquina superior izquierda). De manera similar, en el mosaico 5, el modelo base presenta una alteración cromática con tonos rosáceos, fenómeno que no se observa en los resultados obtenidos con GANtropy.




Figura 4. Resultados cualitativos de inferencias con 1000 muestras de base de Xia et al., 2024. Salazar-Colores et al., 2020 es el modelo base.
Fuente: Autoría propia.

En la figura 5 podemos observar los resultados del modelo base y el modelo propuesto con una base de datos no emparejada (Pan *et al.*, 2022), en el caso de ambos modelos podemos ver que la tarea de eliminación de humo se ha cumplido de manera muy similar; sin embargo, en el modelo base se observa nuevamente la tendencia a la saturación de colores de la escena mientras que GANtropy preserva de forma más fiel este aspecto, este comportamiento es más fácilmente apreciado en escenas como las del mosaico 3, donde vemos la zona de tejido (zonas amarillas y rojas) con un aspecto de color más natural.




Figura 5. Resultados cualitativos de inferencias con 1000 muestras de base de datos de Pan et al., 2022. Salazar-Colores et al., 2020 es el modelo base. Fuente: Autoría propia.

Cuantitativos

Tabla 1. Resultados cuantitativos de PSNR y SSIM.

Conjunto de datos de inferencias	Modelo	PSNR	SSIM
Propio	Salazar-Colores et al., 2020	20.9607±1.2413	0.9056 ± 0.0174
Xia et al., 2024	Salazar-Colores et al., 2020	19.6067 ± 4.231	0.8085 ± 0.1166
Propio	GANtropy	36.5966 ± 1.0776	0.9767 ± 0.0065
Xia et al., 2024	GANtropy	19.3304 ± 3.942	0.8095 ± 0.1078

Fuente: Autoría propia.

En la Tabla 1, correspondiente a las métricas PSNR y SSIM (evaluadas sobre conjuntos emparejados), se observa una mejora significativa en el conjunto de datos propio. El modelo GANtropy alcanzó un PSNR promedio de 36.59 dB y un SSIM de 0.9767, frente a los 20.96 dB y 0.9056 obtenidos por el modelo base. Esto indica que la propuesta logra una restauración más fiel y estructuralmente coherente con la imagen original, reduciendo el nivel de distorsión y preservando mejor los detalles anatómicos.

Por otro lado, en la base de datos de Xia *et al.*, 2024, ambos modelos muestran rendimientos similares (PSNR ≈ 19 dB y SSIM ≈ 0.81), lo que sugiere que el modelo propuesto mantiene su desempeño aun en condiciones distintas a las de su entrenamiento, aunque con menor ventaja frente al modelo base. Esto refleja una capacidad de generalización aceptable, considerando las diferencias entre las bases de datos sintéticas e in vivo.

Tabla 2. Resultados cuantitativos de FADE, NIQE y BRISQUE.

Conjunto de datos de inferencias	Modelo	FADE	NIQE	BRISQUE
Propio	Salazar-Colores <i>et al.</i> , 2020	0.3868 \pm 0.0865	5.5542 \pm 0.8686	12.5187 \pm 5.9137
Pan <i>et al.</i> , 2022.	Salazar-Colores <i>et al.</i> , 2020	0.3517 \pm 0.1186	5.4948 \pm 0.9958	12.5187 \pm 5.9137
Propio	GANtropy	0.3481 \pm 0.0903	5.8242 \pm 0.8395	11.2484 \pm 4.7992
Pan <i>et al.</i> , 2022.	GANtropy	0.3798 \pm 0.2006	6.2076 \pm 1.5192	19.2148 \pm 6.8250

Fuente: Autoría propia.

La Tabla 2 presenta las métricas sin referencia (FADE, NIQE y BRISQUE) utilizadas en las pruebas con imágenes no emparejadas. En el conjunto de datos propio, GANtropy mostró mejoras notables en FADE (0.3481 vs. 0.3868) y BRISQUE (11.25 vs. 12.52), lo que indica una eliminación de humo más efectiva y una calidad perceptual superior. Sin embargo, el valor de NIQE aumentó ligeramente (5.82 vs. 5.55), lo que podría asociarse a pequeñas variaciones en la textura o naturalidad percibida tras la restauración.

En la base de datos Pan *et al.*, 2022, el modelo propuesto obtuvo un FADE mayor (0.3798 vs. 0.3517) y un BRISQUE considerablemente más alto (19.21 vs. 12.52), lo cual sugiere que, aunque elimina el humo de forma visualmente adecuada, su desempeño cuantitativo disminuye cuando se evalúa con datos no emparejados externos. Esto puede deberse a diferencias en las condiciones de iluminación, colorimetría o distribución del humo en dichas imágenes.

En conjunto, los resultados evidencian que GANtropy tiene mejores resultados en comparación al modelo base en escenarios emparejados y mantiene un rendimiento competitivo en escenarios no emparejados, aunque con cierta sensibilidad a las variaciones del dominio de datos.

Conclusión y trabajo a futuro

El modelo GANtropy, que integra un canal guía basado en entropía local, demostró ser una alternativa efectiva para mejorar la eliminación digital de humo en imágenes laparoscópicas. Los resultados cuantitativos y cualitativos muestran que este canal adicional proporciona información contextual útil para distinguir zonas con y sin humo, permitiendo una restauración más selectiva y una preservación más natural de los colores del tejido.

En términos de desempeño, GANtropy mejora la fidelidad y la similitud estructural en datos emparejados, y aunque presenta variaciones en métricas sin referencia cuando se evalúa en dominios externos, conserva la coherencia visual y evita la sobre-saturación cromática observada en el modelo base.



Como línea futura, sería pertinente explorar estrategias de ajuste de dominio o aprendizaje no supervisado, que podrían robustecer la generalización del modelo ante diferentes tipos de escenas laparoscópicas.

Referencias

- Baid, A., Kotwal, A., Bhalodia, R., Merchant, S. N., & Awate, S. P. (2017). Joint desmoking, specularity removal, and denoising of laparoscopy images via graphical models and Bayesian inference. 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017), 732–736. <https://doi.org/10.1109/ISBI.2017.7950623>
- Chen, W.-T., Lou, H.-L., Fang, H.-Y., Chen, I.-H., Chen, Y.-W., Ding, J.-J., & Kuo, S.-Y. (2022). DesmokeNet: A Two-Stage Smoke Removal Pipeline Based on Self-Attentive Feature Consensus and Multi-Level Contrastive Regularization. *IEEE Transactions on Circuits and Systems for Video Technology*, 32(6), 3346–3359. <https://doi.org/10.1109/TCSVT.2021.3106198>
- Gu, L., Liu, P., Jiang, C., Luo, M., & Xu, Q. (2015). Virtual Digital Defogging Technology Improves Laparoscopic Imaging Quality. *Surgical Innovation*, 22(2), 171–176. <https://doi.org/10.1177/1553350614537564>
- Horé, A., & Ziou, D. (2010). Image Quality Metrics: PSNR vs. SSIM. 2010 20th International Conference on Pattern Recognition, 2366–2369. <https://doi.org/10.1109/ICPR.2010.579>
- Kim, C. (2021). Region Adaptive Single Image Dehazing. *Entropy*, 23(11), 1438. <https://doi.org/10.3390/e23111438>
- Kotwal, A., Bhalodia, R., & Awate, S. P. (2016). Joint desmoking and denoising of laparoscopy images. 2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI), 1050–1054. <https://doi.org/10.1109/ISBI.2016.7493446>
- Choi L. K., You, J., & Bovik, A. C. (2015). Referenceless Prediction of Perceptual Fog Density and Perceptual Image Defogging. *IEEE Transactions on Image Processing*, 24(11), 3888–3901. <https://doi.org/10.1109/TIP.2015.2456502>
- Mittal, A., Moorthy, A. K., & Bovik, A. C. (2012). No-Reference Image Quality Assessment in the Spatial Domain. *IEEE Transactions on Image Processing*, 21(12), 4695–4708. <https://doi.org/10.1109/TIP.2012.2214050>
- Mittal, A., Soundararajan, R., & Bovik, A. C. (2013). Making a “Completely Blind” Image Quality Analyzer. *IEEE Signal Processing Letters*, 20(3), 209–212. <https://doi.org/10.1109/LSP.2012.2227726>
- Moreno, H., Salazar-Colores, S., Valentín, L. M., & Flores, G. (2024). Dsmk-DcSeg-Lap, a Generative Adversarial Network Guided by Dark-Chanel and Segmentation to Smoke Removal in Laparoscopic Images. In Z. Lyu (Ed.), *Applications of Generative AI* (pp. 137–160). Springer International Publishing. https://doi.org/10.1007/978-3-031-46238-2_7
- Murabito, F., Spampinato, C., Palazzo, S., Giordano, D., Pogorelov, K., & Riegler, M. (2018). Top-down saliency detection driven by visual classification. *Computer Vision and Image Understanding*, 172, 67–76. <https://doi.org/10.1016/j.cviu.2018.03.005>
- Nilsson, J., & Akenine-Möller, T. (2020). Understanding SSIM (No. arXiv:2006.13846). *arXiv*. <https://doi.org/10.48550/arXiv.2006.13846>
- Pan, Y., Bano, S., Vasconcelos, F., Park, H., Jeong, T. Ted., & Stoyanov, D. (2022). DeSmoke-LAP: Improved unpaired image-to-image translation for desmoking in laparoscopic surgery. *International Journal of Computer Assisted Radiology and Surgery*, 17(5), 885–893. <https://doi.org/10.1007/s11548-022-02595-2>
- Powell, F., & Khaund, A. (2016). Laparoscopy and laparoscopic surgery. *Obstetrics, Gynaecology & Reproductive Medicine*, 26(10), 297–303. <https://doi.org/10.1016/j.ogrm.2016.07.004>
- Salazar-Colores, S., Jiménez, H. M., Ortiz-Echeverri, C. J., & Flores, G. (2020). Desmoking Laparoscopy Surgery Images Using an Image-to-Image Translation Guided by an Embedded Dark Channel. *IEEE Access*, 8, 208898–208909. <https://doi.org/10.1109/ACCESS.2020.3038437>



- Vishal, V., Sharma, N., & Singh, M. (2019). Guided Unsupervised Desmoking of Laparoscopic Images Using Cycle-Desmoke. In L. Zhou, D. Sarikaya, S. M. Kia, S. Speidel, A. Malpani, D. Hashimoto, M. Habes, T. Löfstedt, K. Ritter, & H. Wang (Eds.), *OR 2.0 Context-Aware Operating Theaters and Machine Learning in Clinical Neuroimaging* (pp. 21–28). Springer International Publishing. https://doi.org/10.1007/978-3-030-32695-1_3
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- Wu, R., Zhang, Z., Zhang, S., Gou, L., Chen, H., Zhang, L., Chen, H., & Zuo, W. (2025). Self-Supervised Video Desmoking for Laparoscopic Surgery. In A. Leonardis, E. Ricci, S. Roth, O. Russakovsky, T. Sattler, & G. Varol (Eds.), *Computer Vision – ECCV 2024* (pp. 307–324). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-73220-1_18
- Xia, W., Fan, V., Peters, T., & Chen, E. C. S. (2024). A New Benchmark In Vivo Paired Dataset for Laparoscopic Image De-smoking. In M. G. Linguraru, Q. Dou, A. Feragen, S. Giannarou, B. Glocker, K. Lekadir, & J. A. Schnabel (Eds.), *Medical Image Computing and Computer Assisted Intervention – MICCAI 2024* (Vol. 15001, pp. 3–13). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-72378-0_1

