



ARTÍCULO DE REVISIÓN

Manejo de datos OOD en la generación de imágenes sintéticas: revisión del estado del arte

Handling OOD Data in Synthetic Image Generation: A State-of-the-Art Review

Ariadna Arbolaez Espinosa

ararbolaez@uclv.edu.cu • <https://orcid.org/0009-0005-2752-1986>

María Matilde García Lorenzo

mmgarcia@uclv.edu.cu • <https://orcid.org/0000-0002-1663-5794>

Yusely Ruiz González

yuselyr@uclv.edu.cu • <https://orcid.org/0000-0002-6011-1947>

Rafael E. Bello Pérez

rbellop@uclv.edu.cu • <https://orcid.org/0000-0001-5567-2638>

UNIVERSIDAD CENTRAL “MARTA ABREU” DE LAS VILLAS

Recibido: 2025-09-04 • Aceptado: 2025-10-18

RESUMEN

La generación de imágenes sintéticas mediante modelos generativos ha experimentado un progreso notable, pero la identificación y manejo de datos fuera de distribución (OOD) sigue siendo un reto crítico para la implementación confiable de estos modelos. Esta revisión examina el estado del arte en la detección OOD dentro del contexto de la generación de imágenes sintéticas. Se analizan arquitecturas generativas ampliamente utilizadas, como Wasserstein GAN con penalización de gradiente (WGAN-GP) y StyleGAN2-ADA, junto con métricas de evaluación como la Fréchet Inception Distance (FID). Además, se revisan estrategias recientes que mejoran la discriminación OOD sin necesidad de datos OOD durante el entrenamiento, como SeTAR (que ajusta selectivamente representaciones internas) y ABET (que combina energía y escalado de temperatura aprendido). La síntesis de la literatura indica que la integración de técnicas de detección OOD en los modelos generativos no solo incrementa la capacidad de los modelos para distinguir entre ejemplos en distribución y fuera de distribución, sino que también promueve una mayor fidelidad visual y estabilidad en las imágenes sintéticas, especialmente en escenarios con datos reales limitados o críticos. La revisión concluye identificando vacíos en el conocimiento y proponiendo líneas futuras de investigación para fortalecer la aplicabilidad de estos modelos en dominios sensibles.



Palabras clave: datos fuera de distribución; detección de anomalías; evaluación de modelos; generación de imágenes sintéticas; modelos generativos.

ABSTRACT

Synthetic image generation through generative models (GANs, diffusion models) has seen remarkable progress, but the identification and handling of out-of-distribution (OOD) data remains a critical challenge for the reliable deployment of these models. This review examines the state of the art in OOD detection within the context of synthetic image generation. Widely used generative architectures such as Wasserstein GAN with gradient penalty (WGAN-GP) and StyleGAN2-ADA are analyzed, along with evaluation metrics like Fréchet Inception Distance (FID). Furthermore, recent strategies that enhance OOD discrimination without requiring OOD data during training are reviewed, such as SeTAR (which selectively adjusts internal representations) and ABET (which combines energy and learned temperature scaling). The literature synthesis indicates that integrating OOD detection techniques into generative models not only increases the models' ability to distinguish between in-distribution and out-of-distribution examples but also promotes greater visual fidelity and stability in synthetic images, especially in scenarios with limited or critical real data. The review concludes by identifying gaps in knowledge and proposing future research directions to strengthen the applicability of these models in sensitive domains

Keywords: anomaly detection; generative models; model evaluation; synthetic image generation; out-of-distribution data.



INTRODUCCIÓN

La generación de imágenes sintéticas mediante modelos generativos profundos ha revolucionado áreas como la visión por computadora, el diseño gráfico y la medicina. Arquitecturas como las Redes Generativas Antagónicas (GANs) (I. J. Goodfellow et al., 2014) y, más recientemente, los modelos de difusión (Rombach, Blattmann, Lorenz, Esser, & Ommer, 2022), son capaces de producir muestras visualmente convincentes a partir de distribuciones de datos complejas. Sin embargo, un problema persistente es la dificultad de estos modelos para identificar y manejar datos fuera de distribución (OOD), es decir, ejemplos que se desvían significativamente de la distribución de entrenamiento. Esta limitación puede generar imágenes irrelevantes o de baja calidad (Duy et al., 2021), y supone un riesgo en aplicaciones críticas como el diagnóstico médico (Mahapatra, Bozorgtabar, & Garnavi, 2019; Rayavarapu & Sasibhushana Rao, 2025).

La detección OOD se ha estudiado tradicionalmente en el contexto de clasificación (Yang, Zhou, Li, & Liu, 2024), pero su integración en modelos generativos presenta desafíos únicos. Por un lado, métricas comúnmente utilizadas para evaluar la calidad de imágenes sintéticas, como la Fréchet Inception Distance (FID) (Heusel, Ramsauer, Unterthiner, Nessler, & Hochreiter, 2017), ofrecen una medida indirecta de la similitud entre distribuciones, pero no están diseñadas específicamente para identificar ejemplos OOD. Por otro lado, técnicas recientes como SeTAR (Li,

Chen, Chen, & Xiong, 2024) y los enfoques basados en energía (Liu, Wang, Owens, & Li, 2020) proponen mecanismos para mejorar la discriminación OOD sin requerir datos OOD durante el entrenamiento, lo que las hace particularmente atractivas para escenarios con datos limitados (Karras et al., 2020).

Esta revisión tiene como objetivo examinar el estado del arte en la generación de imágenes sintéticas con foco en la detección OOD. Se analizarán las arquitecturas generativas más relevantes, las métricas de evaluación utilizadas, y las estrategias propuestas para mitigar el problema OOD. La contribución de este trabajo radica en sintetizar los avances recientes, identificar tendencias y brechas en la literatura, y ofrecer perspectivas para futuras investigaciones que fortalezcan la confiabilidad de los modelos generativos en entornos reales.

METODOLOGÍA

Esta revisión sigue un enfoque sistemático para la identificación, selección y análisis de la literatura relevante. Los pasos metodológicos se describen a continuación.

Estrategia de búsqueda

Se realizaron búsquedas en bases de datos académicas (arXiv, IEEE Xplore, SpringerLink, PubMed) y en motores de búsqueda generales (Google Scholar) utilizando combinaciones de los siguientes términos: “synthetic image generation”, “out-of-distribution detection”, “GAN OOD”, “Fréchet Inception Distance”, “WGAN-GP”, “StyleGAN2-ADA”, “SeTAR”, “ABET”, “energy-based OOD detection”. Se incluyeron artículos publicados entre 2015 y 2025, con especial énfasis en los últimos cinco años.

Criterios de selección

Se consideraron artículos de conferencias, revistas y que cumplieran con los siguientes criterios:

1. Que aborden la generación de imágenes sintéticas mediante modelos generativos (GANs, modelos de difusión).
2. Que propongan o evalúen métodos para la detección de datos fuera de distribución en el contexto generativo.
3. Que discutan métricas de evaluación relevantes (FID, Inception Score, etc.).
4. Que presenten aplicaciones en dominios como imágenes médicas, automoción, u otros escenarios con datos limitados.

Extracción y síntesis de la información

De cada artículo seleccionado se extrajo información sobre: arquitectura del modelo, métricas utilizadas, estrategias de detección OOD, resultados principales y limitaciones. La información se organizó en categorías temáticas para facilitar el análisis comparativo y la identificación de tendencias.



RESULTADOS Y DISCUSIÓN

Modelos generativos para imágenes sintéticas

Las Redes Generativas Antagónicas (GANs) han sido la arquitectura dominante para la generación de imágenes, estableciendo un marco de entrenamiento adversarial entre un generador y un discriminador (I. J. Goodfellow et al., 2014; I. Goodfellow et al., 2020). Sin embargo, las GANs originales son propensas a inestabilidades como el colapso modal. Variantes como Wasserstein GAN con penalización de gradiente (WGAN-GP) abordan esto reemplazando el recorte de pesos con una penalización en la norma del gradiente del crítico, mejorando significativamente la estabilidad del entrenamiento y la calidad de las muestras (Gulrajani, Ahmed, Arjovsky, Dumoulin, & Courville, 2017). Para escenarios con datos limitados, StyleGAN2-ADA introduce un aumento de datos adaptativo aplicado al discriminador, lo que previene el sobreajuste y permite una generación de alta fidelidad incluso con conjuntos pequeños (Karras et al., 2020).

Más recientemente, los modelos de difusión han emergido como una alternativa poderosa. Estos modelos, como los Denoising Diffusion Probabilistic Models (DDPM), generan imágenes mediante un proceso iterativo de eliminación de ruido, logrando una calidad excepcional y diversidad (Ho, Jain, & Abbeel, 2020). Su variante eficiente, los Latent Diffusion Models (LDM), realiza este proceso en un espacio latente comprimido, reduciendo el coste computacional (Rombach et al., 2022). No obstante, un hallazgo crítico es que, a pesar de su capacidad para capturar fielmente la distribución de entrenamiento, estos modelos profundos generativos pueden asignar una probabilidad (likelihood) más alta a datos OOD que a los propios datos de entrenamiento (Nalisnick, Matsukawa, Teh, Gorur, & Lakshminarayanan, 2019). Esta paradoja, confirmada también en el contexto específico de los difusores (Kirichenko, Izmailov, & Wilson, 2020), revela una desconexión profunda entre la densidad de probabilidad aprendida y la semántica real de los datos, lo que sugiere limitaciones intrínsecas en la generalización de estos modelos (Wang, Ribeiro, & Mandt, 2024). Por tanto, la confianza interna del modelo no es un indicador fiable para la detección OOD, subrayando la necesidad de desarrollar métricas y mecanismos de detección externos y específicos para garantizar la fiabilidad en entornos abiertos (Yang et al., 2024).

El desafío de los datos fuera de distribución (OOD)

Los datos OOD se definen como ejemplos que se desvían significativamente de la distribución de datos en la que el modelo fue entrenado (Yang et al., 2024). En el contexto generativo, esto se manifiesta de dos formas principales: 1) la generación involuntaria de muestras OOD (por ejemplo, un modelo entrenado en rostros humanos genera un rostro con características anatómicas imposibles), y 2) la incapacidad para rechazar o identificar una entrada OOD durante la inferencia o la evaluación.

Este problema trasciende lo académico y conlleva riesgos sustanciales en aplicaciones críticas. En diagnóstico médico, un generador de imágenes de piel podría producir una lesión sintética que no se corresponda con ninguna patología real, confundiendo a los médicos en formación y planteando un problema de validez clínica y generalización (Mahapatra et al., 2019; Rayavarapu & Sasibhushana Rao, 2025). En seguridad de sistemas autónomos, la incapacidad de detectar una situación OOD en los datos de entrada puede llevar a predicciones o generaciones de escenarios erróneos, violando principios fundamentales de seguridad en IA que requieren robustez frente a distribuciones nuevas (Amodei, 2016; Nitsch et al., 2021). Por lo tanto, la detección y el manejo de OOD dejan de ser un problema marginal para convertirse en un componente esencial de garantía de seguridad y robustez para el despliegue de sistemas generativos.



Dado que las arquitecturas generativas son sumamente vulnerables a los datos OOD, se requiere evaluarlas con métricas adecuadas.

Métricas de evaluación para generación de imágenes

Para medir la calidad de las imágenes generadas, una de las métricas más usadas es la Fréchet Inception Distance (FID) (Heusel et al., 2017). El FID calcula la distancia entre las características de imágenes reales y generadas. Aunque un buen FID suele coincidir con lo que los humanos vemos como una imagen de calidad (Benny, Galanti, Benaim, & Wolf, 2021; Sharma, Kumar, Sharma, & Biju, 2024; Wibowo, Setyawan, Setiawan, & Sembiring, 2025), esta métrica tiene un problema grave para la seguridad: no mide si el modelo puede identificar datos OOD (Chong & Forsyth, 2020).

Esto significa que un modelo generativo puede tener un FID excelente y, al mismo tiempo, fallar completamente cuando se enfrenta a ejemplos fuera de su entrenamiento. Esta es una brecha peligrosa, especialmente en usos críticos como la medicina, donde no se pueden permitir errores con datos nuevos.

Otras métricas como el Inception Score (IS) también se usan (Barratt & Sharma, 2018; Sharma et al., 2024), pero ninguna está diseñada para detectar OOD. Por lo tanto, confiar solo en ellas da una falsa sensación de seguridad. Esto deja claro que se necesitan métodos específicos de detección OOD, que son el tema central de la siguiente sección de esta revisión.

Estrategias específicas para mejorar la detección OOD en modelos generativos

Para superar la limitación de las métricas tradicionales, se han creado métodos cuyo objetivo directo es mejorar la capacidad de los modelos generativos para identificar datos OOD. Dos estrategias recientes y efectivas son SeTAR y ABET.

SeTAR es un método del tipo training-free (no requiere reentrenamiento) que mejora la habilidad de un modelo de visión ya entrenado para detectar OOD. Su mecanismo se basa en ajustar de manera selectiva las matrices de peso de la red mediante una aproximación de bajo rango. Este ajuste interno modifica las representaciones del modelo, haciendo que las activaciones para datos dentro de la distribución y fuera de ella se separen más, lo que facilita su discriminación. La principal ventaja de SeTAR es que logra esta mejora sin necesidad de exponer al modelo a ejemplos OOD durante su desarrollo o ajuste, siendo muy útil para escenarios con datos limitados (Li et al., 2024).

ABET es una estrategia que combina dos conceptos para una detección más precisa. Por un lado, utiliza un score de energía, donde a los datos se les asigna un valor escalar (energía) que tiende a ser más bajo para ejemplos dentro de la distribución y más alto para los OOD. Por otro lado, incorpora un escalado de temperatura aprendido, que es un parámetro que se ajusta automáticamente para afinar la sensibilidad del detector. La combinación de estos dos elementos permite a ABET reducir significativamente la tasa de falsas alarmas (clasificar datos normales como OOD) sin depender de datos OOD durante la fase de entrenamiento del detector (LeVine et al., 2024).

Ambas estrategias representan un avance significativo, ya que abordan el núcleo del problema de la detección OOD en modelos generativos desde enfoques prácticos y eficientes, preparando el terreno para su aplicación en dominios sensibles.



Aplicaciones en dominios sensibles

La detección de OOD es especialmente crítica en el campo de las imágenes médicas. En este dominio, los datos reales de pacientes son a menudo escasos, sensibles y difíciles de obtener (Shin et al., 2018). Los modelos generativos se utilizan para crear imágenes sintéticas que ayuden a entrenar otros sistemas de diagnóstico (Frid-Adar et al., 2018), aumentando así el tamaño de los conjuntos de datos disponibles. Sin embargo, aquí el riesgo es alto: si el generador produce una imagen con anatomía irrelevante, un artefacto extraño o una patología que no se corresponde con la realidad (todos ellos datos OOD), puede confundir a los especialistas o arruinar el entrenamiento de modelos de diagnóstico asistido (Yoon, Oh, Shin, Mazurowski, & Suk, 2024).

Para evitar esto, es necesario integrar mecanismos que detecten y filtren estas generaciones erróneas. Un ejemplo concreto es el uso de la arquitectura StyleGAN2-ADA para generar imágenes sintéticas de hígado a partir de tomografías computarizadas (TC). La investigación demostró que, al combinar este generador con técnicas de detección, se podía identificar y rechazar automáticamente las imágenes que no correspondían a hígado, logrando una precisión de detección muy alta, superior al 90% (Karras et al., 2020; Rayavarapu & Sasibhushana Rao, 2025).

Los métodos específicos de detección OOD, como SeTAR y ABET, son muy prometedores para fortalecer esta aplicación. Sus características principales los hacen ideales para el ámbito médico:

- No necesitan ejemplos de datos OOD para su desarrollo: En medicina, es imposible reunir ejemplos de todas las anatomías o artefactos extraños que podrían aparecer. Tanto SeTAR como ABET están diseñados para mejorar la detección sin requerir este tipo de datos durante su entrenamiento o ajuste (LeVine et al., 2024; Li et al., 2024).
- Son eficientes y ofrecen resultados sólidos: SeTAR logró mejoras significativas en la capacidad de modelos de visión para distinguir datos OOD en conjuntos de prueba generales, actuando como un ajuste posterior al entrenamiento que no requiere recalcular todo el modelo (Li et al., 2024). Por su parte, ABET demostró una gran eficacia para reducir los falsos positivos (es decir, evitar que datos normales sean marcados como extraños) en modelos expuestos a datos novedosos (LeVine et al., 2024).

Limitaciones y brechas de investigación

A pesar de los avances, persisten desafíos. La mayoría de las métricas de evaluación (como FID) no están diseñadas para detectar OOD, y las técnicas específicas para OOD a menudo se evalúan en clasificación, no en generación. Además, la falta de puntos de referencia estandarizados para evaluación OOD en generación dificulta la comparación de métodos. Otra brecha es la integración eficiente de mecanismos de detección OOD en arquitecturas generativas complejas sin comprometer la calidad o velocidad de la generación.

CONCLUSIONES

Esta revisión ha examinado el estado del arte en generación de imágenes sintéticas y detección de datos fuera de distribución. Se constata que, si bien los modelos generativos han alcanzado una notable capacidad para producir imágenes realistas, su vulnerabilidad a datos OOD sigue siendo un punto débil. Arquitecturas como WGAN-GP y StyleGAN2-ADA ofrecen mejoras en estabilidad y calidad, pero por sí mismas no resuelven el problema OOD. Métricas como FID proporcionan una medida indirecta de la similitud entre distribuciones, pero no sustituyen a técnicas específicas de detección OOD.



Estrategias como SeTAR y ABET representan avances prometedores, ya que mejoran la discriminación OOD sin requerir datos OOD durante el entrenamiento, lo que las hace aplicables en escenarios con datos limitados. Sin embargo, su integración en modelos generativos completos aún requiere mayor investigación.

Como direcciones futuras, se identifican: (1) la identificación de métricas de evaluación que combinen calidad generativa y sensibilidad OOD y puntos de referencia estandarizados para evaluar detección OOD en generación de imágenes; (3) la exploración de métodos que puedan adaptarse a diversos modelos generativos sin coste computacional excesivo; y (4) la aplicación de estas técnicas en dominios de alto impacto, como la generación de imágenes médicas para entrenamiento de modelos de diagnóstico.

La integración robusta de detección OOD en los flujos de generación de imágenes no solo aumentará la confiabilidad de los modelos, sino que también ampliará su aplicabilidad en entornos donde la calidad y la seguridad son primordiales.

AGRADECIMIENTOS

Los autores desean expresar su agradecimiento al proyecto “Desarrollo de métodos y herramientas de software para el aprendizaje de redes neuronales federadas y generativas para el uso eficiente y seguro de imágenes médicas”, del programa ARIA, por el apoyo y las facilidades brindadas para la realización de esta investigación.

REFERENCIAS

Amodei, D. (2016). Concrete Problems in AI Safety. <https://doi.org/https://doi.org/10.48550/arXiv.1606.06565>

Barratt, S., & Sharma, R. (2018). A note on the inception score. ArXiv Preprint ArXiv:1801.01973.

Benny, Y., Galanti, T., Benaim, S., & Wolf, L. (2021). Evaluation Metrics for Conditional Image Generation. International Journal of Computer Vision, 129(5). <https://doi.org/10.1007/s11263-020-01424-w>

Chong, M. J., & Forsyth, D. (2020). Effectively unbiased fid and inception score and where to find them. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 6070–6079.

Duy, P. T., Tien, L. K., Khoa, N. H., Hien, D. T. T., Nguyen, A. G. T., & Pham, V. H. (2021). DIGFuPAS: Deceive IDS with GAN and function-preserving on adversarial samples in SDN-enabled networks. Computers and Security, 109. <https://doi.org/10.1016/j.cose.2021.102367>

Frid-Adar, M., Diamant, I., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. Neurocomputing, 321, 321–331.

Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2014). Advances in Neural Information Processing Systems: Generative Adversarial Nets. Advances in Neural Information Processing Systems, 27.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2020). Generative adversarial networks. Communications of the ACM, 63(11). <https://doi.org/10.1145/3422622>



Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. (2017). Improved training of wasserstein GANs. *Advances in Neural Information Processing Systems*, 2017-December.

Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). GANs trained by a two time-scale update rule converge to a local Nash equilibrium. *Advances in Neural Information Processing Systems*, 2017-December. <https://doi.org/10.18034/ajase.v8i1.9>

Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 2020-December.

Karras, T., Aittala, M., Hellsten, J., Laine, S., Lehtinen, J., & Aila, T. (2020). Training generative adversarial networks with limited data. *Advances in Neural Information Processing Systems*, 2020-December.

Kirichenko, P., Izmailov, P., & Wilson, A. G. (2020). Why normalizing flows fail to detect out-of-distribution data. *Advances in Neural Information Processing Systems*, 2020-December.

LeVine, W., Pikus, B., Phillips, J., Norman, B., Gil, F. A., & Hendryx, S. (2024). Out-of-Distribution Detection & Applications With Ablated Learned Temperature Energy. *ArXiv Preprint ArXiv:2401.12129*.

Li, Y., Chen, G., Chen, Y., & Xiong, B. (2024). SeTAR: Out-of-Distribution Detection with Selective Low-Rank Approximation. *NeurIPS*. <https://doi.org/https://doi.org/10.48550/arXiv.2406.12629>

Liu, W., Wang, X., Owens, J. D., & Li, Y. (2020). Energy-based out-of-distribution detection. *Advances in Neural Information Processing Systems*, 2020-December.

Mahapatra, D., Bozorgtabar, B., & Garnavi, R. (2019). Image super-resolution using progressive generative adversarial networks for medical image analysis. *Computerized Medical Imaging and Graphics*, 71. <https://doi.org/10.1016/j.compmedimag.2018.10.005>

Nalisnick, E., Matsukawa, A., Teh, Y. W., Gorur, D., & Lakshminarayanan, B. (2019). Do deep generative models know what they don't know? *7th International Conference on Learning Representations, ICLR 2019*.

Nitsch, J., Itkina, M., Senanayake, R., Nieto, J., Schmidt, M., Siegwart, R., ... Cadena, C. (2021). Out-of-distribution detection for automotive perception. *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, 2938–2943.

Rayavarapu, S. M., & Sasibhushana Rao, G. (2025). Exploración de modelos generativos profundos para una mejor generación de datos en la miocardiopatía hipertrófica. *Ingenius Revista de Ciencia y Tecnología*, (34).

Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-Resolution Image Synthesis with Latent Diffusion Models. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2022-June. <https://doi.org/10.1109/CVPR52688.2022.01042>

Sharma, P., Kumar, M., Sharma, H. K., & Biju, S. M. (2024). Generative adversarial networks (GANs): Introduction, Taxonomy, Variants, Limitations, and Applications. *Multimedia Tools and Applications*, 83(41). <https://doi.org/10.1007/s11042-024-18767-y>



Shin, H.-C., Tenenholtz, N. A., Rogers, J. K., Schwarz, C. G., Senjem, M. L., Gunter, J. L., ... Michalski, M. (2018). Medical image synthesis for data augmentation and anonymization using generative adversarial networks. International Workshop on Simulation and Synthesis in Medical Imaging, 1–11.

Wang, Z., Ribeiro, F., & Mandt, S. (2024). On the Paradox of Learning to Reason from Data: Can We Learn Out-of-Distribution? *Transactions on Machine Learning Research*. <https://doi.org/https://doi.org/10.48550/arXiv.2205.11502>

Wibowo, M. C., Setyawan, I., Setiawan, A., & Sembiring, I. (2025). Deep Learning-Based Visualization of Network Threat Patterns Using GAN-Generated Infographic. *Jurnal RESTI*, 9(4). <https://doi.org/10.29207/resti.v9i4.6717>

Yang, J., Zhou, K., Li, Y., & Liu, Z. (2024). Generalized Out-of-Distribution Detection: A Survey. *International Journal of Computer Vision*, 132(12). <https://doi.org/10.1007/s11263-024-02117-4>

Yoon, J. S., Oh, K., Shin, Y., Mazurowski, M. A., & Suk, H.-I. (2024). Domain generalization for medical image analysis: A review. *Proceedings of the IEEE*.

Copyright © 2025, Autores: Arbolaez Espinosa, Ariadna, García Lorenzo, María Matilde, Ruíz González, Yusely, Bello Pérez, Rafael E..



Esta obra está bajo una licencia de Creative Commons Atribución-No Comercial 4.0 Internacional