

Reconstrucción de video de alto rango dinámico mediante técnicas modernas de aprendizaje de maquina: un análisis extensivo de metodologías actuales

Cristopher Ochoa-Villanueva, Thuanne Paixão, D. B. Luque, Ana Beatriz Alvarez.

Universidade Federal do Acre, Rodovia BR 364, Rio Branco - AC, Brasil.

Recibido el 20 de junio del 2025. Aprobado el 30 de junio del 2025. Publicado el 1 de julio del 2025

<https://doi.org/10.33017/RevECIPeru2025.0002/>

Resumen

El alto rango dinámico (HDR del inglés High Dynamic Range) permite representar escenas visuales complejas manteniendo detalles tanto en áreas muy iluminadas como en regiones oscuras. En el caso de video, esta tarea se complica debido al movimiento y los cambios entre fotogramas consecutivos. Una alternativa efectiva para generar secuencias HDR sin depender de sensores especializados consiste en fusionar múltiples imágenes de bajo rango dinámico (LDR de Low Dynamic Range) tomadas con distintas exposiciones, proceso conocido como reconstrucción de video HDR. Sin embargo, este procedimiento enfrenta dos retos principales: reducir artefactos visuales y lograr una ejecución eficiente para aplicaciones en tiempo real. Para abordar esta tarea, se han reproducido arquitecturas basadas en aprendizaje profundo, particularmente en redes neuronales convolucionales (CNN), que integran procesos de alineación, fusión y restauración de contenido visual. En este trabajo se comparan tres de estas arquitecturas: LAN-HDR, HDRFlow y NECHDR. La evaluación se realizó utilizando los conjuntos de datos Cinematic Video y DeepHDRVideo, y se aplicaron métricas cuantitativas junto con un análisis cualitativo de los resultados visuales. Finalmente, se examinó la complejidad computacional requerido por cada arquitectura, identificando fortalezas, debilidades y desafíos actuales en la reconstrucción de video HDR.

Descriptores: *High Dynamic Range, Reconstruccion de video HDR, LAN-HDR, HDRFlow, NECHDR*

Abstract

High Dynamic Range (HDR) imaging enables the representation of visually complex scenes by retaining detail in both highly illuminated and dark regions. In video applications, this task becomes more challenging due to motion and variations across consecutive frames. An effective alternative to producing HDR sequences without relying on specialized—and often expensive—sensors involves fusing multiple Low Dynamic Range (LDR) images captured at different exposure levels, a process known as HDR video reconstruction. However, this approach faces two primary challenges: minimizing visual artifacts and achieving efficient execution suitable for real-time applications. To address these challenges, deep learning-based architectures have been developed, particularly those utilizing Convolutional Neural Networks (CNNs), which integrate alignment, fusion, and restoration stages to reconstruct visual content. This work compares three such architectures: LAN-HDR, HDRFlow, and NECHDR. The evaluation was conducted using the Cinematic Video and DeepHDRVideo datasets, applying both quantitative metrics and qualitative analysis of the reconstructed frames. Lastly, the computational complexity of each model was assessed in terms of efficiency and performance, identifying their strengths, limitations, and ongoing challenges in HDR video reconstruction.

Keywords: *High Dynamic Range, HDR Video Reconstruction, LAN-HDR, HDRFlow, NECHDR*

1. Introducción

Las imágenes de alto rango dinámico (HDR, por sus siglas en inglés High Dynamic Range) son una tecnología diseñada para reproducir escenas con un nivel de fidelidad visual cercano a lo que el ojo humano percibe en entornos reales. Esta capacidad se traduce en una mejora significativa en la calidad visual de imágenes y videos mediante la ampliación del rango de luminancia y la gama de colores, lo que permite preservar detalles tanto en regiones oscuras como intensamente iluminadas [1].

Una estrategia viable para generar secuencias HDR sin necesidad de emplear sensores especializados, los cuales suelen ser costosos y poco accesibles, consiste en reconstruir fotogramas HDR a partir de la fusión de múltiples imágenes de bajo rango dinámico (LDR, Low Dynamic Range) capturadas con diferentes exposiciones [2]. Este enfoque permite capturar escenas de alto contraste utilizando equipos convencionales [3]. Sin embargo, en contextos de video, donde existen desplazamientos complejos entre fotogramas, la reconstrucción HDR enfrenta dos retos fundamentales: evitar la introducción de artefactos visuales y garantizar una ejecución eficiente para aplicaciones en tiempo real [4].

El aprendizaje profundo ha emergido como una solución prometedora frente a estos desafíos, dando lugar al desarrollo de métodos de reconstrucción de video HDR basados en redes neuronales convolucionales (CNN, Convolutional Neural Networks) que abordan simultáneamente la alineación, fusión y restauración de contenido visual degradado [5] [6]. La mayoría de los enfoques actuales se alinean con la estrategia propuesta inicialmente por Kalantari et al. [7] en el contexto de imágenes HDR, que plantea un esquema de dos etapas incluyendo, alineamiento entre imágenes y posterior fusión HDR. Para llevar a cabo este proceso, diversos trabajos han incorporado técnicas de estimación de flujo óptico para mejorar la calidad del alineamiento, junto con redes convolucionales que integran las diferentes exposiciones en una única reconstrucción libre de artefactos, como se evidencia en [8][9].

El entrenamiento de estas arquitecturas se ha basado, en su mayoría, en conjuntos de datos sintéticos. Entre los más utilizados se encuentran Vimeo-90K [10] y MPI Sintel [11], ambos ampliamente empleados en tareas de estimación de flujo óptico. No obstante, dado que no están diseñados específicamente para reconstrucción HDR, ha sido necesario convertir sus secuencias

originales en videos LDR con exposiciones alternadas, aplicando técnicas propuestas por diversos autores [12][13]. Para la evaluación del rendimiento, fueron utilizadas bases de datos que contienen escenas reales tanto estáticas como dinámicas, como Cinematic Video [14] y DeepHDRVideo [12], las cuales permiten validar el desempeño bajo condiciones realistas.

En este trabajo se presenta un análisis del comportamiento de diversas arquitecturas enfocadas en reconstrucción de video HDR tales como LAN-HDR [15], HDRFlow [16] y NECHDR [17]. La evaluación cuantitativa se basa en las métricas PSNR y SSIM, mientras que la eficiencia computacional se analiza a través del conteo de parámetros, las operaciones de punto flotante (FLOPs) y el tiempo de inferencia. Finalmente, es llevado a cabo una evaluación cualitativa de los resultados, con el objetivo de identificar las fortalezas y limitaciones de cada enfoque, así como destacar los principales desafíos que aún persisten en la reconstrucción de video HDR, y sugerir posibles líneas de mejora futura.

2. Metodología

Tres arquitecturas representativas del estado del arte en reconstrucción de video HDR fueron analizadas, siendo LAN-HDR, HDRFlow y NECHDR, correspondientes a enfoques basados en luminancia, flujo óptico y exposiciones, respectivamente. Todas emplean secuencias de imágenes LDR con exposiciones alternadas como entrada.

2.1. Conjunto de datos

Fueron empleados los conjuntos de datos CinematicVideo [14] y DeepHDRVideo [12], diseñados para configuraciones de dos y tres exposiciones. Del conjunto CinematicVideo se utilizaron las secuencias POKER FULLSHOT y CAROUSEL FIREWORKS, que contienen 60 fotogramas LDR con exposición alternada, alineados con 56 imágenes HDR de referencia.

El conjunto de datos DeepHDRVideo se encuentra segmentado en secuencias dinámicas y estáticas, estructuradas según la cantidad de exposiciones. En la *Tabla 1* se muestra información de este conjunto de datos.

Tabla 1: Estructura del conjunto de datos DeepHDRVideo.

DeepHDRVideo		Dinámico	Estático
2E	Nro. Escenas	19 (4 sub-escenas)	49
	Nro. LDRs	5/sub-escena	6
	Nro. HDRs	1/sub-escena	6
3E	Nro. Escenas	18 (6 sub-escenas)	48
	Nro. LDRs	7/sub-escena	9
	Nro. HDRs	1/sub-escena	9

2.2 LAN-HDR

La arquitectura LAN-HDR, propuesta en [15], tiene su esquema mostrado en la *Figura 1* donde se procesan secuencias LDR mediante un alineamiento espacial en el dominio de luminancia, complementado por un módulo de alucinación que recupera detalles en zonas sobresaturadas. Esta combinación genera el fotograma HDR.




Figura 1: Arquitectura LAN-HDR

2.3 HDRFlow

Esta arquitectura es propuesta por Xu et.al [16]. En la *Figura 2* se ilustra el proceso de reconstrucción realizado por la arquitectura, que inicia con un preprocesamiento y concatenación de los fotogramas LDR alimentando un módulo de estimación de flujo óptico, basado en kernels de gran tamaño. A partir del fotograma central como referencia, es calculado y aplicado el alineamiento espacial de los fotogramas vecinos. El conjunto resultante, junto con las imágenes LDR originales, es procesado en el módulo de fusión para generar la reconstrucción HDR final.




Figura 2: Arquitectura HDRFlow

2.4 NECHDR

La arquitectura de Cui [17], representada en la *Figura 3*, aborda la predicción de exposiciones faltantes mediante dos procesos, siendo finalización de exposición y renderizado HDR. Las características extraídas de los fotogramas de entrada se procesan en el bloque de renderizado HDR para estimar los flujos ópticos, que permiten alinear los fotogramas vecinos al fotograma de referencia. Esta alineación sirve de base para la finalización de exposiciones. Las exposiciones completadas, junto con las características originales, se integran en el decodificador HDR para generar un fotograma HDR aproximado. Finalmente, este resultado, junto con los fotogramas originales y el fotograma de exposición completada, se fusionan para obtener una reconstrucción HDR de alta calidad.




Figura 3: Arquitectura NECHDR

2.5. Métricas de evaluación

El desempeño de las arquitecturas se evalúa mediante métricas cuantitativas que permiten medir la calidad visual y la fidelidad de la reconstrucción HDR. Serán usadas las métricas PSNR (*Peak Signal-to-Noise Ratio*) y SSIM (*Structural Similarity Index Measure*) de acuerdo con [19].

2.6. Métricas de coste computacional

Basado en [20], las métricas para estimar la complejidad de las arquitecturas son el número de parámetros, la cantidad de FLOPs (*Floating Point Operations*), y el tiempo de inferencia. El número de parámetros representa la cantidad de pesos que el modelo aprende y almacena; un mayor número implica un modelo más voluminoso y con mayores requerimientos de memoria. Por su parte, los FLOPs reflejan el total de operaciones en coma flotante necesarias para reconstruir una imagen HDR; valores más altos implican un mayor costo computacional. Finalmente, el tiempo de inferencia mide el tiempo real que tarda el modelo en procesar una imagen HDR, dependiendo tanto de las métricas anteriores como del hardware utilizado.

3. Experimentos y resultados

Los modelos fueron reproducidos utilizando el lenguaje Python 3.10 y ejecutados en el framework PyTorch. Todos los experimentos se llevaron a cabo en un entorno de hardware compuesto por una GPU RTX 3050 de 4 GB, un procesador Intel i7-12700H y 64 GB de memoria RAM.

Dado que las imágenes HDR no pueden visualizarse directamente en dispositivos convencionales, es necesario aplicar un mapeo de tonos para su correcta representación. Para ello, se empleó la pérdida HALoss (HDR-domain Alignment Loss), introducida en [16], la cual permite una conversión precisa de brillo directamente en el dominio HDR. Esta pérdida se calcula mediante una transformación basada en la ecuación (1).

$$\mathcal{T}(H) = \frac{\log(1+\mu H)}{\log(1+H)} \quad (1),$$

Donde, H representa la imagen HDR reconstruida, μ es un factor de escalado luminoso fijado en 5000, y $\mathcal{T}(H)$ es la imagen transformada tras aplicar el mapeo de tonos.

3.1 Análisis cuantitativo

La *Tabla 2* presenta los resultados de las métricas PSNR y SSIM para cada arquitectura evaluada, correspondientes a los conjuntos de datos CinematicVideo, y DeepHDRVideo en sus variantes de escenas dinámicas y estáticas. Los valores de PSNR y SSIM fueron obtenidos sobre las imágenes HDR reconstruidas tras la aplicación del mapeo de tonos, representadas con el sufijo -T.

La arquitectura NECHDR se destaca por obtener los mejores resultados en todas las métricas de calidad para la configuración de 2 exposiciones, lo que indica que la predicción de exposiciones faltantes contribuye significativamente a mejorar la reconstrucción de video HDR. Cuando analizado el comportamiento para la configuración de 3 exposiciones, y al evaluar SSIM, se verifica que esta arquitectura aún se mantiene con el mejor desempeño. Por otro lado, al ser evaluado el PSNR, las tres arquitecturas presentan un comportamiento competitivo. También, al analizar el desempeño de la arquitectura HDRFlow, se percibe que presenta el segundo mejor comportamiento, con métricas PSNR y SSIM competitivas en los conjuntos CinematicVideo y DeepHDRVideo con escenas estáticas. Ya para contextos dinámicos, el comportamiento de LAN-HDR es significativo, quedando atrás apenas de NECHDR.

3.2 Análisis cualitativo

Para el análisis cualitativo son consideradas escenas de los conjuntos de datos CinematicVideo y DeepHDRVideo dinámico.

Considerando CinematicVideo, las *Figuras 4 y 5* presentan las tres imágenes LDR de entrada, la imagen HDR de referencia GT (Ground Truth) y los resultados de las reconstrucciones HDR generadas por cada arquitectura para las escenas POKER FULLSHOT y CAROUSEL FIREWORKS, respectivamente. Se incluyen detalles de las regiones seleccionadas para examinar visualmente cómo cada método reconstruye las complejidades de la región.

En la escena POKER FULLSHOT, se nota que la reconstrucción obtenida con NECHDR consigue recuperar mejor los detalles finos en regiones altamente iluminadas en comparación a las dos otras arquitecturas. Detalladamente, en las regiones marcadas de rosa y celeste, se percibe una mejor definición estructural de las cartas tomadas por cada jugador y sus contornos, además que también se nota una mejor definición de las manos y sus respectivas sombras. En la reconstrucción por HDRFlow y LAN-HDR, se visualiza la presencia de artefactos en las manos provocando la pérdida del contorno de las cartas.

En la escena CAROUSEL FIREWORKS, NECHDR se destaca por reconstruir mejor la estructura del mecanismo, se percibe mejor los bordes de las lámparas coloridas y de las formas del objeto. Al comparar la reconstrucción por NECHDR con el GT, se evidencia que, si bien se consigue reconstruir regiones dinámicas, hay limitaciones en la definición de detalles pequeños como en las luces del carrusel. Por otro lado, en la reconstrucción por HDRFlow y LAN-HDR se evidencian la presencia de artefactos luminosos que deforman los detalles de la estructura y las luces del carrusel.

Considerando el conjunto de datos DeepHDRVideo en escenas dinámicas, la escena 17 es elegida para el análisis debido a su condición de baja iluminación. La *Figura 6* presenta los resultados de las reconstrucciones realizadas, NECHDR demuestra el mejor desempeño en comparación a HDRFlow y LAN-HDR. Al visualizar el contorno del brazo se nota una mejor definición, en contraste a las otras, que presentan artefactos a lo largo del brazo llevando a deformaciones de su forma. Al comparar el resultado de NECHDR con el GT, se observa la presencia de artefactos en los dedos evidenciando su insuficiencia en este tipo de condición.

Tabla 2: Comparación cuantitativa de los métodos en el conjunto de datos CinematicVideo, DeepHDRVideo Dinámico y DeepHDRVideo Estático. **Negrita:** mejor, subrayado: segundo mejor.

Conjunto de datos	Método	2 exposiciones		3 exposiciones	
		PSNRT	SSIMT	PSNRT	SSIMT
Cinematic Video	LAN-HDR	38.219334	0.906983	35.067524	0.871861
	HDRFlow	<u>39.4327</u>	<u>0.9154</u>	<u>36.6254</u>	<u>0.9037</u>
	NEC-HDR	40.6065	0.9241	37.2675	0.9115
DeepHDRVideo Dynamic	LAN-HDR	44.79392	<u>0.97129</u>	42.434861	<u>0.976804</u>
	HDRFlow	<u>45.5679</u>	0.9683	41.4957	0.968
	NEC-HDR	45.6304	0.9715	<u>41.9279</u>	0.9775
DeepHDRVideo Static	LAN-HDR	39.113065	0.932317	<u>39.014981</u>	0.93374
	HDRFlow	<u>41.1117</u>	<u>0.9354</u>	39.6887	<u>0.9392</u>
	NEC-HDR	41.8418	0.9447	38.3002	0.9399

3.3 Análisis de coste computacional

Los resultados que muestran el desempeño de cada arquitectura en relación con el coste computacional de las mismas están descritos en las Tablas 3 y 4, para 2 y 3 exposiciones, respectivamente. Para LAN-HDR, debido a su complejidad estructural, no fueron calculados el número de parámetros y FLOPs.

En términos de eficiencia, HDRFlow registró la menor cantidad de parámetros seguido por NECHDR que, aunque con un número mayor de parámetros ofrece un equilibrio favorable con un número reducido de FLOPs.

HDRFlow también se destaca por su rapidez en el tiempo de inferencia, superando a las demás arquitecturas evaluadas, con NECHDR en segunda posición. En cambio, LAN-HDR fue la más lenta, debido a la división de su procesamiento en módulos de alineamiento y alucinación, los cuales implican una alta demanda computacional.

Tabla 3: Comparación del coste computacional para 2 exposiciones

Método	Parámetros(M)	FLOPs(T)	Tiempo(ms)
LAN-HDR	-	-	527.889
HDRFlow	3.270	0.191	33.111
NECHDR	8.828	0.880	61.149

Tabla 4: Comparación del coste computacional para 3 exposiciones

Método	Parámetros(M)	FLOPs(T)	Tiempo(ms)
LAN-HDR	-	-	672.799
HDRFlow	5.331	0.381	42.444
NECHDR	8.484	0.757	78.386

3.4 Desafíos y tendencias futuras

A partir de los resultados obtenidos en los análisis cuantitativos y cualitativos, se percibe un comportamiento destacado de la arquitectura NECHDR en la reconstrucción de video HDR frente a las demás. Esto debido a su metodología basada en la finalización de exposiciones. Los próximos desafíos pueden visar la reducción de su complejidad computacional.

Por su parte, HDRFlow, fundamentada en el uso de flujo óptico, mostró una alta capacidad de reconstrucción en escenarios estáticos, combinada con un tiempo de inferencia y requerimiento computacional eficiente, gracias al empleo de kernels de gran tamaño para el procesamiento del flujo. No obstante, sus próximos desafíos deben enfocarse en mejorar la respuesta ante escenas altamente dinámicas y entornos con baja iluminación.

En contraste, LAN-HDR, que incorpora módulos de alineamiento y alucinación, presenta importantes limitaciones en la calidad de reconstrucción debido a la presencia de artefactos luminosos. Cuando es analizada su eficiencia computacional, se verifica también limitaciones significativas, pues es la arquitectura con el mayor tiempo de procesamiento.

Desafíos futuros pueden considerar una optimización de la arquitectura.




Figura 4: Comparación cualitativa en el conjunto de datos CinematicVideo, escena POKER FULLSHOT.



Figura 5: Comparación cualitativa en el conjunto de datos CinematicVideo, escena CAROUSEL FIREWORKS.




Figura 6: Comparación cualitativa en el conjunto de datos DeepHDRVideo dinámico, escena 19.

4. Conclusiones

Este trabajo presenta un análisis comparativo de tres arquitecturas para la reconstrucción de video HDR, siendo LAN-HDR, HDRFlow y NECHDR, las cuales se fundamentan respectivamente en módulos de alineamiento y alucinación, estimación de flujo óptico con kernels amplios, y finalización de exposiciones. La evaluación se llevó a cabo utilizando los conjuntos de datos CinematicVideo, DeepHDRVideo, a través de implementaciones experimentales que incluyeron métricas cuantitativas (PSNR y SSIM), análisis cualitativos y estimaciones del costo computacional.

Los resultados obtenidos confirman que NECHDR alcanzó el mejor desempeño tanto a nivel cuantitativo como cualitativo en escenas estáticas y dinámicas. En términos de costo computacional, NECHDR demanda un poco más de capacidad de cómputo, por ende, su rendimiento superior puede justificar esta necesidad. Por su parte, HDRFlow demostró ser una opción competitiva gracias a su calidad de reconstrucción razonable y tiempos de inferencia notablemente reducidos, ofreciendo una reconstrucción HDR con una exigencia mínima de recursos.

En términos generales, la reconstrucción de video HDR representa una línea de investigación prometedora cuando se aborda mediante técnicas de aprendizaje profundo. Además, esta tarea puede potenciarse integrando otros procesos complementarios, como la superresolución y la reconstrucción de imágenes HDR, con el objetivo de mejorar aún más la calidad visual del resultado final.

Agradecimientos

Los autores agradecen el respaldo brindado por el Laboratorio PAVIC, el cual se beneficia de los incentivos fiscales otorgados por SUFRAMA, conforme a lo establecido en la Ley brasileña N.º 8387/1991.

Referencias

- [1] Zaixi Shang, Joshua P Ebenezer, Abhinav K Venkataramanan, Yongjun Wu, Hai Wei, Sriram Sethuraman, and Alan C Bovik. A study of subjective and objective quality assessment of hdr videos. *IEEE Transactions on Image Processing*, 33:42–57, 2023.
- [2] Josue Lopez-Cabrejos, Thuanne Paixão, Ana Beatriz Alvarez, and Diodomiro Baldomero Luque. An efficient and low-complexity transformer-based deep learning framework for high-dynamic-range image reconstruction. *Sensors*, 25(5):1497, 2025.
- [3] Byeong Dae Lee and Myung Hoon Sunwoo. Hdr image reconstruction using segmented image learning. *IEEE Access*, 9:142729–142742, 2021.
- [4] Mrinal Anand, Nidhin Harilal, Chandan Kumar, and Shanmuganathan Raman. Hdrvideo-gan: deep generative hdr video reconstruction. In *Proceedings of the twelfth indian conference on computer vision, graphics and image processing*, pages 1–9, 2021.

- [5] Fan Zhang, Di Ma, Chen Feng, and David R Bull. Video compression with cnn- based postprocessing. *IEEE MultiMedia*, 28(4):74–83, 2021.
- [6] Gustavo de Souza Ferreti, Thuanne Paixão, and Ana Beatriz Alvarez. Generative adversarial network-based lightweight high-dynamic-range image reconstruction model. *Applied Sciences*, 15(9):4801, 2025.
- [7] Nima Khademi Kalantari, Ravi Ramamoorthi, et al. Deep high dynamic range imaging of dynamic scenes. *ACM Trans. Graph.*, 36(4):144–1, 2017.
- [8] David Hafner, Oliver Demetz, and Joachim Weickert. Simultaneous hdr and optic flow computation. In *2014 22nd International Conference on Pattern Recognition*, pages 2065–2070. IEEE, 2014.
- [9] Feiyue Peng, Maojun Zhang, Shiming Lai, Hanlin Tan, and Shen Yan. Deep hdr reconstruction of dynamic scenes. In *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, pages 347–351. IEEE, 2018.
- [10] Tianfan Xue, Baian Chen, Jiajun Wu, Donglai Wei, and William T Freeman. Video enhancement with task-oriented flow. *International Journal of Computer Vision*, 127:1106–1125, 2019.
- [11] Sarah Alnegheimish, Dongyu Liu, Carles Sala, Laure Berti-Equille, and Kalyan Veeramachaneni. Sintel: A machine learning framework to extract insights from signals. In *Proceedings of the 2022 International Conference on Management of Data*, pages 1855–1865, 2022.
- [12] Guanying Chen, Chaofeng Chen, Shi Guo, Zhetong Liang, Kwan-Yee K. Wong, and Lei Zhang. Hdr video reconstruction: A coarse-to-fine network and a real-world benchmark dataset. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pages 2502–2511, October 2021.
- [13] Nima Khademi Kalantari and Ravi Ramamoorthi. Deep hdr video from sequences with alternating exposures. In *Computer graphics forum*, volume 38, pages 193–205. Wiley Online Library, 2019.
- [14] Jan Froehlich, Stefan Grandinetti, Bernd Eberhardt, Simon Walter, Andreas Schilling, and Harald Brendel. Creating cinematic wide gamut hdr-video for the evaluation of tone mapping operators and hdr-displays. In *Digital photography X*, volume 9023, pages 279–288. SPIE, 2014.
- [15] Haesoo Chung and Nam Ik Cho. Lan-hdr: Luminance-based alignment network for high dynamic range video reconstruction. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pages 12760–12769, 2023.
- [16] Gangwei Xu, Yujin Wang, Jinwei Gu, Tianfan Xue, and Xin Yang. Hdrflow: Real-time hdr video reconstruction with large motions. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 24851–24860, 2024.
- [17] Jiahao Cui, Wei Jiang, Zhan Peng, Zhiyu Pan, and Zhiguo Cao. Exposure completing for temporally consistent neural high dynamic range video rendering. In *Proceedings of the 32nd ACM International Conference on Multimedia*, pages 10027–10035, 2024.
- [18] Nima Khademi Kalantari, Eli Shechtman, Connelly Barnes, Soheil Darabi, Dan B Goldman, and Pradeep Sen. Patch-based high dynamic range video. *ACM Trans. Graph.*, 32(6):202–1, 2013.
- [19] Gabriel de Lima Martins, Josue Lopez-Cabrejos, Julio Martins, Quefren Leher, Gustavo de Souza Ferreti, Lucas Hidelbrano Costa Carvalho, Felipe Bezerra Lima, Thuanne Paixão, and Ana Beatriz Alvarez. A review toward deep learning for high dynamic range reconstruction. *Applied Sciences*, 15(10):5339, 2025.
- [20] Cheng Guo and Xiuhua Jiang. Lhdr: Hdr reconstruction for legacy content using a lightweight dnn. In *Proceedings of the Asian Conference on Computer Vision*, pages 3155–3171, 2022.