
This is the **published version** of the bachelor thesis:

Martín Merino, Paula; Vázquez i Corral, Javier, dir. Millora d'imatges capturades al vespre. Anàlisi de mètodes tradicionals i deep learning i exploració d'un enfocament híbrid. 2024. (Enginyeria Informàtica)

This version is available at <https://ddd.uab.cat/record/298934>

under the terms of the  license

Millora d'imatges capturades al vespre. Anàlisi de mètodes tradicionals i deep learning i exploració d'un enfoc híbrid

Paula Martín Merino

1 de juliol de 2024

Resum– El processament d'imatges nocturnes representa un desafiament important en el camp de la fotografia a causa de la baixa il·luminació i la presència de soroll, fet que dificulta la captura de detalls i la reproducció precisa del color. En aquest treball investiguem i comparem mètodes tradicionals de processament d'imatges amb enfocaments basats en deep learning per millorar la qualitat d'imatges nocturnes. A més explorem la combinació d'aquests enfocaments per avaluar si la integració d'ambdós mètodes donen millors resultats.

Els mètodes tradicionals de processament d'imatges tenen limitacions i sovint no aconsegueixen produir resultats satisfactoris. Per altra banda, els enfocaments basats en deep learning, especialment les xarxes neuronals convolucionals (CNN), han demostrat ser eficaces en el processament d'imatges i el reconeixement de patrons.

Paraules clau– Deep Learning, Xarxes Convolucionals (CNN)

Abstract– The processing of nighttime images represents a significant challenge in the field of photography due to low illumination and the presence of noise, which complicates capturing details and accurate color reproduction. In this work, we investigate and compare traditional image processing methods with deep learning-based approaches to enhance the quality of nighttime images. Additionally, we explore the combination of these approaches to assess whether the integration of both methods yields better results.

Traditional image processing methods have limitations and often fail to produce satisfactory results. On the other hand, deep learning-based approaches, particularly convolutional neural networks (CNNs), have proven to be effective in image processing and pattern recognition.

Keywords– Deep Learning-based, Convolutional neural networks (CNNs)

1 INTRODUCCIÓ

LA millora en la qualitat de les imatges nocturnes és un desafiament constant en l'àmbit del processament d'imatges. Les limitacions inherents a la captura d'imatges en condicions de baixa il·luminació, alt soroll, baix contrast i falta de detall requereixen el desenvolupament de mètodes avançats per al processament i millora d'imatges. Aquest treball s'emmarca en la necessitat de desenvolupar eines efectives per millorar la qualitat de les

imatges nocturnes, que són crítiques en diverses aplicacions com la seguretat, la vigilància, la fotografia nocturna, la conducció autònoma i la monitorització ambiental.

En les imatges nocturnes, la baixa il·luminació causa problemes significatius com el soroll electrònic, que pot distorsionar els detalls importants de l'escena. A més, el baix contrast entre les regions il·luminades i les ombrívoles dificulta la identificació clara dels objectes i les característiques de la imatge. Això planteja un repte tant per als mètodes tradicionals de processament d'imatges com per a les tècniques més modernes basades en xarxes neuronals convolucionals (CNN) [8].

En aquest treball, es proposa una comparació exhaustiva entre els mètodes tradicionals de millora d'imatges i les xarxes convolucionals, utilitzant un conjunt de dades d'imatges nocturnes. S'exploren diverses tècniques de processament

- E-mail de contacte: 1495012@uab.cat
- Menció realitzada: Computació
- Treball tutoritzat per: Javier Vázquez (departament)
- Curs 2023/24

d'imatges, com ara el filtrat de soroll, l'ajust del contrast i la millora de la nitidesa, i es comparen amb els resultats obtinguts mitjançant la xarxa U-Net, una arquitectura de xarxa neuronal convolucional dissenyada específicament per a la segmentació d'imatges.

Els objectius principals d'aquest treball són:

- Comprovar si els mètodes tradicionals de millora d'imatges poden ser més eficients que les xarxes convolucionals.
- Examinar com la utilització de xarxes convolucionals és més o menys addient depenent del punt del pre-processat en el que s'apliquen. Això implica l'estudi de com els pre-processaments inicials poden influir en la capacitat de la xarxa U-Net per produir imatges de major qualitat, així com la variabilitat dels resultats depenent del tipus d'imatge d'entrada.

A mesura que la tecnologia continua avançant, l'ús de tècniques basades en intel·ligència artificial per al processament d'imatges nocturnes s'ha convertit en una àrea d'investigació activa. No obstant això, és important no subestimar l'eficàcia dels mètodes tradicionals, que poden oferir solucions ràpides i eficients en determinades circumstàncies. Aquest treball pretén contribuir a aquesta àrea d'investigació, proporcionant una anàlisi comparativa detallada i oferint recomanacions per a futures millores en el camp de la millora d'imatges nocturnes.

2 ESTAT DE L'ART

Per abordar aquest desafiament, s'ha implementat un pipeline de processament d'imatges basat en el codi font proporcionat pel Night Imaging Challenge [10]. Aquest pipeline inclou diverses tècniques de processament d'imatges com l'estimació de la il·luminació [16], mapatge de to [3], variació de contrast [11] i reducció de soroll [1]. A més, s'han implementat diferents mètodes per millorar el contrast i la nitidesa de les imatges.

Aquest pipeline s'ha complementat amb l'entrenament d'una xarxa convolucional profunda, concretament una U-net, per crear un model híbrid i intentar obtenir millors resultats que amb només un mètode tradicional. Tanmateix, cal destacar que, seguint el treball dels investigadors italians [17] en què ens hem inspirat, s'ha demostrat que els mètodes tradicionals poden ser més eficients en certs aspectes.

Els investigadors italians van proposar un pipeline ISP tradicional per al processament de fotografies nocturnes, que consistia en 5 passos principals:

- Processament RAW: Inclou la normalització dels nivells de negre i blanc, la demosaicació per convertir la imatge RAW d'un sol canal en una imatge en color complet, l'aplicació de l'algoritme de balanç de blancs Gray World, i la conversió de l'espai de color específic de la càmera a l'espai de color sRGB.
- Reducció de Soroll: Utilitzen l'algoritme Non-local means per eliminar el soroll d'adquisició, preservant els detalls de la imatge. Es descomposa la imatge en components de luminància i cromà, aplicant una reducció de soroll més intensa als canals de cromà.

- Millora del Contrast: Aplicació de tècniques per millorar el contrast de la imatge, incloent la correcció de contrast local (LCC), la correcció de contrast global, la correcció de corbes en S, l'estirament d'histogrames, i la correcció de contrast condicional.
- Millora de la Nitidesa: Utilitzen el masking no afilat per augmentar el contingut d'alta freqüència, augmentant el contrast percebut entre les vores i les regions planes
- Balanç de Blancs: Apliquen inicialment en l'etapa de processament RAW l'algoritme Gray World, seguit d'una segona operació de balanç de blancs més sofisticada per reduir les dominants de color típiques de les escenes nocturnes.

A més, els investigadors italians van proposar l'ús de deep learning en pipelines ISP, que poden substituir els diferents algorismes tradicionals per una única xarxa neuronal. Aquestes solucions han demostrat resultats prometedors però presenten limitacions significatives, com la necessitat de grans conjunts de dades d'entrenament, un elevat cost computacional i una limitada explicabilitat.

En l'estudi dels investigadors italians, es veu que la motivació per intentar combinar mètodes tradicionals, com són algorismes d'un pipeline, amb xarxes neuronals és a causa de l'èxit de l'aprenentatge profund en molts aspectes de la computació. Tanmateix, aquests mètodes requereixen una gran quantitat de dades emparellades RAW-RGB per poder mapejar una imatge RAW d'entrada en la RGB final. Per tant, la falta de conjunts d'imatges nocturnes, juntament amb alts requisits computacionals, representen serioses limitacions.

3 METODOLOGIA I PLANIFICACIÓ

Pel desenvolupament d'aquest projecte s'ha decidit utilitzar la metodologia Agile, aquesta permet adaptar la forma de treball aconseguint flexibilitat i eficàcia. Dintre de les diferents possibilitats dins les metodologies àgils s'ha escollit Kanban. Aquesta metodologia permet tenir una visualització global de la gestió del projecte, permet veure els diferents fluxos de treball i la càrrega. Les tasques es poden trobar en 3 estats diferents: tasques pendents, tasques en curs i tasques finalitzades. L'eina utilitzada ha sigut Trello [15].

Respecte de la planificació inicial del projecte va haver-hi diferents contratemps que van enrederir el progrés del treball. Però l'estructura que s'ha seguit consisteix en les següents passes:

- Fase Inicial: Aquesta fase s'ha basat a fer un previ estudi de què es basava el Night Imaging Challenge i quins eren els objectius al que es volien arribar.
- Implementació de codi base: A partir del codi extret del challenge s'ha implementat diferents mètodes de contrast per acabar de definir la fase de processament d'imatges amb el mètode tradicional. Un cop implementada s'ha processat un conjunt d'imatges.
- Implementació de la U-net: A partir d'una u-net extreta d'internet s'ha adaptat a les necessitats requerides per poder entrenar un model de processament d'imatges.

- Documentació: En aquest darrer pas s'ha redactat l'informe final i el resultat obtinguts del projecte, així com una discussió de les conclusions finals.

4 ENTORN DE DESENVOLUPAMENT

Durant el desenvolupament del treball s'ha utilitzat un entorn de treball i diferents llibreries pel correcte desenvolupament.

4.1 Entorn

Com a entorn de desenvolupament s'ha utilitzat Pycharm [12]. És un entorn de programació python. A més és un entorn de computació amb GPU que serveix per accelerar el procés d'entrenament de la U-Net.

4.2 Llibreries

Pel desenvolupament del codi s'ha utilitzat el llenguatge de programació Python [13]. Concretament, la versió 3.9, s'ha utilitzat aquesta versió per temes de compatibilitat amb llibreries. Les llibreries que s'han utilitzat són les següents:

- NumPy: és una llibreria fonamental per a càlculs numèrics i manipulació d'arraïms en Python. En el projecte ha sigut de gran utilitat per a preparar les dades d'entrenament.
- PyTorch: és un paquet de deep learning que proporciona tensors multidimensionals, operacions GPU i eines per crear i entrenar xarxes neuronals. Ha sigut de gran utilitat per la definició i entrenament de la U-Net.
- Torchvision: llibreria que proporciona conjunts de dades, models preentrenats i transformacions d'imatges comunes. S'ha utilitzat per a les transformacions de les imatges d'entrada, com ara redimensionament i conversió a tensors, així com emmagatzematge d'imatge generades.
- OpenCV: llibreria de visió per computador que proporciona eines per a processar imatges i vídeos. En el projecte s'ha utilitzat per a la lectura i processament d'imatges d'entrada i sortida.
- Matplotlib: és una llibreria de gràfics 2D per a visualització de dades. Ha sigut de gran utilitat pels gràfics de pèrdua d'entrenament en la U-Net.
- Tqdm: llibreria que proporciona barres de progrés durant l'entrenament per a loops. Durant l'entrenament ha sigut de gran ajut per veure el progrés.
- Pathlib: llibreria per treballar amb rutes del sistema de fitxer i directoris.
- JSON: és una llibreria estàndard de Python per a treballar amb fitxer JSON. Ha sigut de gran ajut per la lectura i manipulació de dades en format JSON per al processament d'imatges.
- Pillow: llibreria per a la manipulació d'imatge. S'ha utilitzat per a les operacions d'imatges com redimensionament i conversió.

5 MÈTODE TRADICIONAL: PIPELINE DE PROCESSAMENT

Per al processament inicial de les imatges s'ha utilitzat el codi font del GitHub del Night Imaging Challenge [7].

S'inicialitza el pipeline per cada imatge d'entrada i s'aplica les següents tècniques de processament:

- Estimació de la il·luminació: per ajustar la il·luminació global de la imatge.
- Mapatge de tons: per ajustar els tons de les imatges, millorant el contrast.
- Reducció de soroll: per a minimitzar el soroll en les imatges, millorant la qualitat visual.

Un cop es fa aquest preprocessament es realitza la millora de contrast, concretament s'hi ha empleat 5 mètodes de millora de contrast. S'aplica una millora de contrast i finalment un balanç de tons blancs i conversió a escala de grisos.

Els 5 mètodes de millora de contrast són:

- Contrast local: Millora el contrast local d'una imatge utilitzant la tècnica CLAHE [11]. S'estableix un límit de contrast i es millora el contrast del canal de lluminositat. Aquesta tècnica és útil per millorar detalls en imatges que tenen regions obscures o de baix contrast.



Fig. 1: Contrast Local Inicial



Fig. 2: Contrast Local Final

- Contrast mig: Ajusta el contrast d'una imatge utilitzant la transformació lineal escalant els píxels de la imatge original. Apliquem un factor d'escala alpha i un valor beta. Aquesta és útil per augmentar o disminuir el contrast en canviar l'escala dels valors dels píxels.
- Contrast correcció de corba: S'aplica una correcció de corba a les imatges utilitzant una taula de consultes (LUT). Aquesta tècnica permet modificar els valors dels píxels de la imatge per millorar el contrast i l'aparença de manera no lineal.



Fig. 3: Contrast Mig Inicial



Fig. 4: Contrast Mig Final



Fig. 5: Correcció corba Inicial



Fig. 6: Correcció corba Final

- Estirament d'histograma: Millora el contrast d'una imatge utilitzant la tècnica d'equalització de l'histograma. Consisteix a redistribuir els nivells d'intensitat dels píxels.



Fig. 7: Estirament Histograma Inicial




Fig. 8: Estirament Histograma Final

- Contrast condicional: S'aplica una modificació de contrast diferent depenent de si el valor d'un píxel es troba per sobre o per sota d'un llindar específic.



Fig. 9: Contrast Condicional Inicial



Fig. 10: Contrast Condicional Final

6 XARXA CONVOLUCIONAL: U-NET

Per desenvolupar la U-net hem agafat el codi base de l'estudi Medical Segmentation Review: The Success of U-Net [6]. Hem anat modificant aquesta xarxa per adaptar-la a les nostres necessitats.

El codi base agafat bàsicament es distribueix en dues parts principals: l'encoder, que redueix la dimensió de l'entrada i destaca les característiques més importants, i el decoder, que reconstrueix la imatge segmentada a partir de les característiques de l'encoder.

Aquest codi consta de dues classes:

- DoubleConv: és un bloc fonamental per la U-Net. Consisteix en dues capes convolucionals seguides de funcions d'activació ReLU [2]. S'utilitzen dues capes consecutives per augmentar la capacitat de la xarxa d'aprendre característiques complexes de les imatges.
- UNet: es defineix bàsicament l'arquitectura de la xarxa. En aquesta classe es troben els mòduls d'encoder i decoder, definicions de les operacions d'upsampling i maxpooling. A més s'incorpora les definicions del nombre d'entrades i sortides i l'ús d'activacions ReLU.

Per tenir una idea més gràfica de com la U-Net creada es pot veure en la figura 11.

6.1 Modificacions

De la U-Net inicial s'han fet una sèrie de modificacions per poder adaptar-la a les necessitats del projecte. Les modificacions han sigut les següents:

- Ajust en els canals d'entrada i sortida: s'ha modificat la U-Net per treballar amb imatges RGB, per tant, es va modificar per treballar amb 3 canals d'entrada i sortida. Originalment, la U-Net estava preparada per

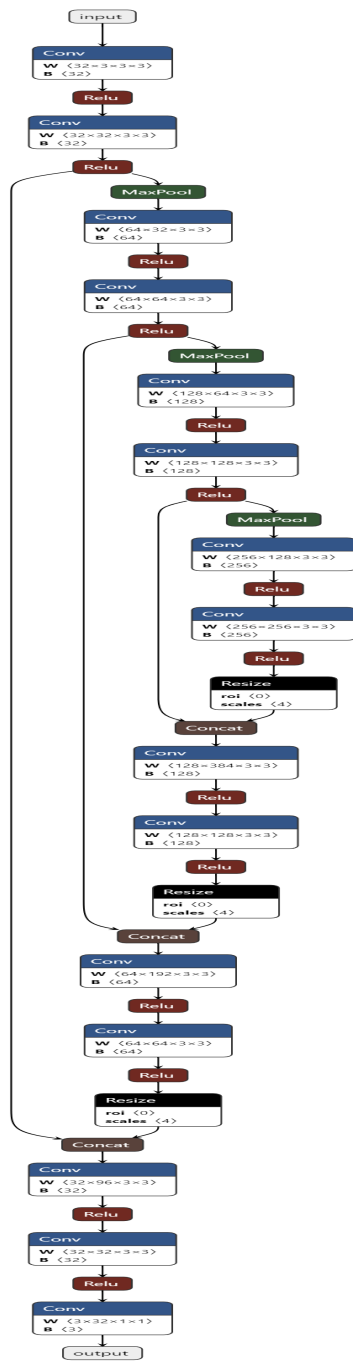


Fig. 11: U-Net

treballar amb diferents tipus d'imatges, però es va enfocar en imatges RGB.

- Escalat d'imatge: es va adaptar per treballar amb imatges redimensionades a una resolució específica per millorar la consistència en l'entrenament i l'avaluació.
- Optimització i pèrdua: es va escollir un optimitzador concretament Adam [14] i una funció de pèrdua com MSELoss per ajustar millor els paràmetres del model en la tasca de millorar la qualitat de les imatges nocturnes.

6.2 Entrenament

Per poder entrenar aquesta U-net hem agafat l'entrada i la sortida utilitzada en el mètode tradicional.

Com vam implementar 4 mètodes de contrast vam escollir el que millors resultats donava que és la Correcció de corba, dona una imatge més neta i detallada que la resta de mètodes de contrast.

Durant aquest procés d'entrenament vam utilitzar un nombre d'èpoques de 100, el qual indica el nombre d'iteracions completes que el model realitza sobre el conjunt de dades d'entrenament. Aquest nombre d'iteracions permet al model aprendre progressivament els detalls de les dades i ajustar els seus pesos per millorar el rendiment.

Primerament, vam fer una prova amb un nombre d'èpoques de 10 per comprovar el funcionament de la U-net i veure com el nombre d'èpoques reflectia directament en els resultats obtinguts.

El dataset amb què vam treballar constava d'unes imatges de partida totalment negres en format PNG juntament amb el seu format JSON i les imatges de sortida agafades del mètode tradicional en format JPG.

Per veure diferents resultats i comparar també vam fer la prova agafant imatges que havien passat un processament base.

La primera prova amb només 10 iteracions, partint de les imatges en negre, vam comprovar que tot i que la U-net en cada iteració anava aprenent els resultats no eren gens bons.

7 RESULTATS

En aquest apartat es presenten els resultats obtinguts amb el processament d'imatges utilitzant dos mètodes: el mètode tradicional i la xarxa neuronal U-Net. També es discutirà la qualitat de les imatges reconstruïdes i el comportament de la U-Net durant l'entrenament.

7.1 Processament d'imatges

En ambdós mètodes de processament d'imatges, tan tradicional com amb U-Net, inicialment partim d'una imatge totalment negra juntament amb la seva corresponent imatge JSON. Els resultats obtinguts són significativament diferents entre els dos enfocaments.

Amb el mètode tradicional, el processament de les imatges és molt més ràpid i eficient. Una de les imatges resultants després d'aquest processament es pot veure en la figura 12. Com es pot observar, partint d'una imatge totalment negra, obtenim molt bons resultats amb una bona reducció de soroll.

En canvi, partint d'una imatge totalment en negre amb la U-net tot i fer 100 iteracions, els resultats no són gens satisfactoris. La imatge resultant després del processament es mostra en la figura 14.

Es pot veure que la imatge resultant no té cap detall clar i no es pot apreciar gairebé res.

Per estudiar més profundament el comportament de la U-Net, es va partir d'una imatge amb un mínim de processament per veure els resultats obtinguts (figura 16). Els resultats millorats es poden veure a la figura 17. A diferència de la primera execució partint d'una imatge negra, obtenim resultats més similars als obtinguts amb el mètode tradicional. Aquesta millora és deguda a diversos factors:

- Informació Visual Inicial: Quan la U-Net processa imatges parcialment processades, aquestes ja conte-



Fig. 12: Exemple 1 Processament tradicional



Fig. 13: Exemple 2 Processament tradicional



Fig. 14: Exemple 1 Processament U-net

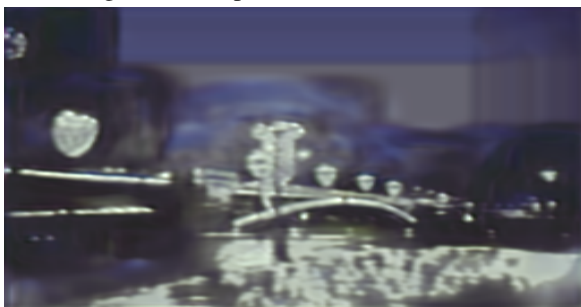


Fig. 15: Exemple 2 Processament U-net

nen certa informació útil com detalls bàsics de lluminositat i contrast. Aquestes pistes permeten al model començar amb una base de dades més rica i facilita l'aprenentatge de patrons i característiques més complexes. En contrast, les imatges negres no contenen cap informació visual i el model ha de treballar més dur augmentant la dificultat de l'entrenament.

- Reducció de Soroll i Preprocessament: Les imatges preprocessades han passat per etapes preliminars de reducció de soroll i una petita millora de contrast, proporcionant una entrada més neta al model. Aquest preprocessament elimina interferències que dificultarien l'aprenentatge del model, permetent-li centrar-se a mi-

llorar la qualitat general de la imatge en lloc de corregir problemes bàsics.

- Aprenentatge: La U-Net té una capacitat d'aprenentatge profund, però aquesta capacitat es veu millorada quan se li proporciona informació inicial adequada. Les imatges parcialment processades actuen com a un punt intermedi, oferint un millor context per a la xarxa per aprendre relacions i característiques visuals complexes. Això no només accelera el procés d'entrenament, sinó que també pot millorar la capacitat del model per generalitzar noves imatges.
- Interacció amb JSON: Els arxius JSON contenen metadades valuoses que poden guiar el processament d'imatges, però quan s'utilitzen amb imatges en negre, el model té la tasca addicional d'integrar aquesta informació textual amb una manca de context visual. Això fa que l'entrenament sigui menys efectiu i més complex.



Fig. 16: Imatge U-net inicial



Fig. 17: Imatge U-net final

7.2 Qualitat de les imatges reconstruïdes

Tot i que la U-Net ha donat pitjors resultats en el processament de les imatges que el mètode tradicional, s'ha calculat el Peak Signal-to-Noise Ratio (PSNR) per avaluar la qualitat de les imatges reconstruïdes en comparació amb les originals. Aquesta mètrica mesura la relació senyal-soroll.

En la primera execució, s'ha obtingut un PSNR de 16.7939 dB, el que indica que es poden veure moltes diferències entre la imatge original i la reconstruïda i que la qualitat de la imatge és molt baixa. En canvi, en la segona execució partint de la imatge preprocessada, s'ha obtingut un PSNR de 38.9648 dB, el que significa que la imatge té una bona qualitat amb petites diferències que a vegades l'ull humà no pot percebre.



Fig. 18: Imatge U-net inicial 2



Fig. 19: Imatge U-net final 2

7.3 Qualitat de la U-net

Per assegurar-nos que la U-Net funciona correctament en cada iteració, es calcula la pèrdua (loss), que mesura com de bé funciona el model. Si la pèrdua disminueix en cada iteració, significa que el nostre model està aprenent en cada una de les iteracions.

Com es pot veure en les figures 20 i 21, a mesura que augmenten les iteracions, la pèrdua disminueix, indicant que la U-Net funciona correctament i aprèn en cada iteració. Tot i això, hi ha pics de pujada en alguna iteració, que solen ser deguts a la varietat de les dades, imatges amb característiques diferents que el model encara no maneja del tot bé.

Aquestes observacions mostren que la diferència en les imatges de partida afecta directament l'agilitat d'aprenentatge de la U-Net i els resultats obtinguts.

8 CONCLUSIONS

En aquest treball s'ha abordat el desafiament de millorar la qualitat de les imatges nocturnes mitjançant l'ús de mètodes tradicionals i xarxes neuronals convolucionals, concretament la U-net. Els resultats obtinguts mostren clarament que els mètodes tradicionals ofereixen millors resultats.

Els objectius inicials eren demostrar que els mètodes tradicionals de millora d'imatges poden ser més eficients que les xarxes convolucionals i veure com imatges de sortida diferents produeixen resultats variats en la U-net. Els resultats obtinguts recolzen fermament aquests objectius, ja que hem demostrat l'eficàcia dels mètodes tradicionals i la variabilitat en el resultat de la U-net.

En conclusió, els mètodes tradicionals de processament d'imatges continuen sent una eina valuosa per a la millora de la qualitat de les imatges nocturnes, i la combinació amb xarxes neuronals pot oferir resultats prometedors quan es parteix d'imatges prèviament processades. Aquesta investigació continua en la línia dels italians, on es veia clarament




Fig. 20: PSNR U-net imatge en negre




Fig. 21: PSNR U-net imatge en preprocessada

que les xarxes convolucionals no són efectives en aquest àmbit.

8.1 Treballs futurs

En l'àmbit de la millora d'imatges mitjançant xarxes neuronals convolucionals, hi ha varies línies d'investigació i desenvolupament per on explorar per poder millorar l'eficiència i la qualitat dels resultats obtinguts. Algunes propostes poden ser:

- **Optimització del model:** reduir paràmetres en la xarxa pot fer que el model sigui més lleuger i ràpid. N'hi ha tècniques de poda de xarxes neuronals i quantització. També utilitzar models més petits. N'hi ha alternatives més eficients en termes de comunicació i memòria com són la MobileNet i EfficientNet.
- **Entrenament de dades:** crear dades sintètiques que simulin diferents condicions d'il·luminació i soroll poden ajudar a entrenar un model més robust. L'opció d'aprofitar models preentrenats en grans conjunts de dades i ajustar-los al problema en específic pot reduir temps d'entrenament i millora de rendiment.
- **Millora de l'arquitectura:** implementar Multi-Attention [4], mecanismes d'atenció en l'arquitectura U-Net per permetre que el model s'enfoqui en les característiques més rellevants.
- **Optimització del procés d'inferència:** implementar tècniques de quantització de models per reduir la mida del model i accelerar el procés d'inferència sense comprometre la precisió.
- **Integració amb altres models:** nosaltres hem fet un model híbrid amb mètodes tradicionals i la U-Net, es pot plantejar combinar amb altres arquitectures com

GANs [9] per millorar la qualitat de les imatges generades i fer front a desafiaments específics com el soroll i la falta de nitidesa.

- Acceleració de hardware especialitzat: explorar e investigar sobre l'ús del hardware neuromòrfic [5], està dissenyat per imitar l'estructura i el funcionament del cervell humà, per millorar l'eficiència energètica i el rendiment de les xarxes neuronals.

A l'abordar aquests temes, no només aconsegueixen millorar les imatges de manera més eficient i efectiva, sinó que també es poden obrir noves possibilitats per aplicacions a temps real i en dispositius amb recursos limitats.

REFERÈNCIES

- [1] Abdelrahman Abdelhamed, Stephen Lin, and Michael S Brown. A high-quality denoising dataset for smartphone cameras. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1692–1700, 2018.
- [2] EITCI Instituto Europeo de Certificación TI. ¿cómo la función de activación "relu" filtra valores en una red neuronal?, 2023.
- [3] Paul Debevec and Simon Gibson. A tone mapping algorithm for high contrast images. In *13th eurographics workshop on rendering: Pisa, Italy. Citeseer*, volume 2, 2002.
- [4] Moonsoo Ra Dejun Zhang, Whoi-Yul Kim. A multi-attention unet for semantic segmentation in remote sensing images. In *Symmetry 2022*. School of Electronics and Communications Engineering, North China University of Technology, School of Information and Electronics, Beijing Institute of Technology, Qian Xuesen Laboratory of Space Technology, China Academy of Space Technology, 2022.
- [5] Esco E-Universitas. Computación neuromórfica, imitando al cerebro, 2022.
- [6] Reza Azad Ehsan, Afshin Bozorgpour. Awesome unet, 2022.
- [7] Egor Ershov. Night photography rendering challenge, 2021.
- [8] MathWorks. ¿qué son las redes neuronales convolucionales?, 2017.
- [9] MathWorks. Introducción a las redes generativas antagonicas (gan), 2020.
- [10] Russian Academy of Sciences IITP. Night photography rendering challenge 2024, 2024.
- [11] Etta D Pisano, Shuquan Zong, Bradley M Hemminger, Marla DeLuca, R Eugene Johnston, Keith Muller, M Patricia Braeuning, and Stephen M Pizer. Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. *Journal of Digital imaging*, 11:193–200, 1998.
- [12] PyCharm. Pycharm: El ide de python para la ciencia de datos y el desarrollo web, 2024.
- [13] Python. Python: programming language, 2024.
- [14] Jan Schäfer. Estimación adaptativa del momento: entender a adam y utilizarlo correctamente, 2024.
- [15] Trello. Trello: Organize anything, together, 2024.
- [16] Joost Van De Weijer and Theo Gevers. Color constancy based on the grey-edge hypothesis. In *IEEE International Conference on Image Processing 2005*, volume 2, pages II–722. IEEE, 2005.
- [17] Simone Zini, Claudio Rota, Marco Buzzelli, Simone Bianco, and Raimondo Schettini. Back to the future: a night photography rendering isp without deep learning. In *CVPR Workshops*, 2023.