

---

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

Company Macarrón, Albert; Vazquez Corral, Javier, dir. Millora d'imatges antigues mitjançant tècniques de processament d'imatge i visió per computador. 2022. (958 Enginyeria Informàtica)

---

This version is available at <https://ddd.uab.cat/record/264223>

under the terms of the  license

# Millora d'imatges antigues mitjançant tècniques de processament d'imatge i visió per computador

Albert Company Macarrón

**Resum**— Aquest article vol fer una anàlisi del procés de millora d'imatge per algoritmes automatitzats. L'objectiu de l'anàlisi és determinar com són de bons els resultats de diferents models de processament d'imatges així com rendiment en diferents escenaris. En aquest paper també es debatrà sobre les nombroses maneres de determinar la qualitat objectiva d'una imatge. És crucial assegurar que les imatges usades per provar els algorismes són realment fotografies antigues i no generades sintèticament. Aquest informe és part d'un projecte de TFG.

**Paraules clau**— aprenentatge profund, reducció de sorolls, millora, conjunt de dades, colorització.

**Abstract**— This article is willing to analyze the process of image enhancement by automated algorithms. The aim of the analysis is to determine how good is the result of different image processing models as well as their performance in various scenarios. This paper will also discuss the variety of ways to determine an objective quality of an image. It is crucial to ensure that the photos used to prove each algorism are truly old photos and are not synthetically generated. This report is part of a TFG project.

**Keywords**— deep-learning, denoising, enhancement, dataset, colorization.



## 1 INTRODUCCIÓ

El present projecte sorgeix a partir de la proposta del professor Javier Vazquez, tutor del treball. Les imatges s'han convertit en una part essencial de la vida d'una persona així com dels seus records i vivències viscudes, no obstant les imatges antigues disposen moltes vegades d'una baixa qualitat ja sigui a causa de les limitacions tècniques del moment que van ser preses o als defectes que el pas del temps i la mala conservació han generat.

És per això que es proposa l'ús tant de tècniques de processament d'imatge i algoritmes *deep-learning* per implementar un model capaç de generalitzar en la millora de la qualitat d'imatges antigues. Gràcies a models de l'estil es poden realitzar aquestes millores de manera molt més ràpida i eficient del que seria realitzant el procés manualment.

La tasca és molt complexa a causa de la quantitat de variables que determinen la qualitat d'una imatge així com la manera en què es valora, que no és única i compta amb un valor subjectiu difícil de quantificar. Això genera models dolents en generalitzar, que obtenen bons resultats en la millora d'un tipus molt concret d'imatge, però al tractar amb altres, els resultats empitjoren considerablement.

Un altre de les característiques que comparteixen la gran part d'aquests models és que l'entrenament s'ha dut a terme amb imatges sintètiques, és a dir, imatges que han sigut empitjorades per tal de presentar els defectes de les

imatges antigues. El procés és molt útil pel fet que podem utilitzar la imatge original com a *ground truth*, a més de tenir grans quantitats dades d'entrenament. Però té un gran inconvenient, a l'haver estat entrenat amb imatges sintètiques, el procés de millora amb imatges antigues reals no assoleix tants bons resultats.

És per això que s'ha proposat realitzar una anàlisi profund de diversos models de millora d'imatges, que hagin aconseguit bons resultats, amb diverses imatges. Es buscaran models que implementin solucions diferents, centrant-se en àmbits diferents de la millora d'imatge, però amb el mateix fi. Per satisfer l'objectiu es proposen altres de més específics:

- Selecció dels diferents models que seran provats i tenir per cada un d'ells el codi per fer-los funcionar.
- Selecció de les diferents imatges a millorar així com les mètriques tant locals com globals que es provaran.
- Implementar un codi per tal d'avaluar les mètriques de les imatges generades per cada un dels models.
- Anàlisi detallada de cada un dels models, en quins escenaris funcionen millor i el perquè.

## 2 REQUISITS

Pel que fa a projectes de visió per computador com és aquest, els llenguatges de programació que solen ser usats són principalment *Matlab* i *Python*, ja que consten amb llibreries tant pel tractament d'imatges com la implementació de models *deep-learning*.

Com a *entornament* pel seu desenvolupament s'utilitzarà

- E-mail de contacte: 1490992@uab.cat
- Menció de Computació
- Treball tutoritzat per Javier Vazquez
- Curs 2021/22

principalment *Google Colab* per a l'execució dels models, pel fet que ens facilita molt el procés d'instal·lació d'un projecte en tenir totes les llibreries disponibles, i *Matlab* pel desenvolupament de la resta de codi.

### 3 PLANIFICACIÓ

El desenvolupament del projecte consta de les següents tasques principals:

1. Cerca i documentació dels models a provar, on a més hem d'obtenir el codi del projecte i entendre el seu funcionament així com documentació de les mètriques a utilitzar.
2. Selecció del conjunt d'imatges per dur a terme les proves, la idea és que siguin variades per tal de provar els punts forts i febles dels models i poder concretar quin d'ells s'adapta millor a quin tipus d'imatge.
3. Desenvolupament d'un codi que ens avaluï la qualitat de la imatge que li hàgim passat amb les diferents mètriques corresponents i extregui gràfics amb els resultats.
4. Fer una anàlisi exhaustiva dels resultats obtinguts per tal d'analitzar el funcionament dels models amb imatges antigues reals.

Cal destacar també que durant el procés de desenvolupament del projecte es realitzen *sprints* setmanals amb el tutor, on es posen en comú els avanços així com diferents idees i propostes pel mateix.

La planificació del projecte ha canviat lleugerament respecte a l'anteriorment plantejada. Els principals canvis venen donats pel fet de repartir les tasques del projecte de tal manera que no formessin blocs tant separats i es treballassin conjuntament per poder extreure resultats i amb aquests millorar el desenvolupament. En la figura 5, adjuntada a l'annex, podem veure el diagrama actualitzat i detallat per setmanes i que ha estat modificat adaptar-lo als canvis.

Pel que fa al compliment de la planificació, si bé és veritat que s'han complert els objectius principals, que són el tenir un codi funcional i poder fer la prova de diversos models per veure quin rendiment obteníem, hi ha hagut imprevistos, com el fet que dos dels models que havien estat proposats no han pogut ser implementats, que han fet que el projecte s'hagi desviat de la planificació original. És per això que s'ha modificat el diagrama de Gantt per adaptar-lo als canvis.

En la planificació inicial es contemplava un tercer model per a implementar al conjunt de les imatges així com tenir la implementació de les imatges referencials. El segon objectiu s'ha complert tal com estava planificat, però a l'hora de trobar el tercer model s'han trobat inconvenients que han fet que no pugui ser funcional per totes les imatges desitjades, fet que ha fet que es modifiqui lleugerament el plantejament del projecte i s'incloguin imatges en blanc i negre en el nostre dataset.

## 4 METODOLOGIA

### 4.1 Models a provar

En aquest apartat es farà una anàlisi dels diferents models que es volen usar per a la millora de les imatges, estudiant les seves fortaleces i la seva viabilitat pel conjunt d'imatges que es vol utilitzar en el projecte.

Durant el desenvolupament del projecte es va considerar una idea interessant no únicament analitzar els resultats de diferents models *deep-learning*, sinó també fer una comparació amb algorismes de processament d'imatge amb molt bons resultats.

#### 4.1.1 Models deep-learning

Es caracteritzen per l'ús d'algorismes d'aprenentatge supervisat per construir models capaços de generalitzar en la millora de la qualitat d'imatge. Solen fer ús d'imatges sintètiques per a l'entrenament, i és per això que es vol provar el seu funcionament amb imatges veritablement antigues.

Els models [1] i [2] han estat descartats per la poca accessibilitat al codi del projecte.

##### 4.1.1.1 Bringing Old Photos Back to Live

El projecte [3] destaca pel seu èmfasi en la millora de la degradació d'imatges antigues i en el fet que el seu model sigui capaç de generalitzar i donar bon rendiment en aquest tipus d'imatges. Aquest model és entrenat amb imatges sintètiques i funciona fent ús del *latent-space* entre la foto vella i la neta.

Consta amb un *notebook* en *google Colab*, amb una demo funcional on es passen els inputs a millorar i genera les imatges resultants. És el que s'ha usat per extreure els resultats d'aquest model.

##### 4.1.1.2 DeOldify GAN Based Image Colorization

DeOldify [4] fa ús d'una *Generative Adversarial Networks* per tal d'entrenar el seu model en la millora d'imatges. Consta de una versió de codi obert pel processament de les imatges, amb dues versions disponibles, l'estable i l'artística.

Existeix un inconvenient principal per l'ús del model dins del nostre projecte, que aquest es centra únicament en



Figura 1: Imatge del resultat de DeOldify en imatges a color. A l'esquerra la imatge original i a la dreta la imatge modificada.

la colorització d'imatges en blanc i negre, però no realitza cap millora substancial a imatges de color, que existeixen en el nostre dataset tal com es mostra a la figura 1.

Tot i que no sigui un mètode útil per tot el conjunt de les imatges del projecte, s'ha conservat aquesta implementació en el treball per provar el seu funcionament en imatges en blanc i negre o colors sepia. D'aquesta manera es comparará el seu rendiment amb els altres model dins aquests escenaris concrets.

#### 4.1.1.3 MirNet Learning Enriched Features for Fast Image Restoration and Enhancement

El model [5] és utilitzat per la realització d'una millora general en imatges. No està específicament destinat al funcionament amb imatges antigues, però dins dels processos que usa per complir el seu objectiu es troben el *denoising* i *enhancement*, que són molt utilitzats en la millora d'imatges antigues. És per això que s'ha volgut afegir aquest model dins dels plantejats pel projecte.

En provar el model trobem un problema substancial en el funcionament del *enhancement*, està pensat per millorar les imatges en condicions de llum molt escasses, no per fer una millora del color de la imatge.



Figura 2: Imatge del resultat de MIRNet. A l'esquerra la imatge original i a la dreta la imatge modificada.

Tal com mostra la figura 2, en tractar-se de imatges amb llum estàndard el model les tracta com a imatges fosques donat un resultat molt empitjorat.

Tot i no poder ser usat per l'*enhancement* de les imatges, s'ha conservat el model pel fet que sí fa un bon *denoising*, i es vol comprovar si és millor que el que s'usarà en els models de processament d'imatge lineal.

#### 4.1.2 Models de processament d'imatge lineal

En canvi els mètodes de processament d'imatge fan ús de funcions matemàtiques per generar una millora en la imatge original. Són molt menys complets que els models anteriors, centrant-se únicament en un aspecte de la millora d'imatge, i és per això que es pot fer ús d'una combinació d'ells per a obtenir millors resultats.

Un altre dels aspectes a tenir en compte, és que els models consten de múltiples paràmetres a l'hora de ser executats. Per mantenir la idea d'usar models que generalitzin en la millora d'imatges i evitar un *tunning* de cada una

d'elles, s'han establert uns paràmetres estandarditzats per tot el conjunt.

##### 4.1.2.1 Automatic Color Enhancement (ACE) and it's Fast Implementation

El mètode [6] fa ús de l'*histrogram equalization* per construir un model capaç de realitzar un *color enhancement* de la imatge.

Per a fer l'execució del model s'ha fet ús de la demo funcional que trobem en l'article [6], els paràmetres han estat estandarditzats amb una  $\omega$  de  $1/r$ , el mètode *Level interpolation* amb 8 nivells i un *enhancement strength* de 5 o 3 dependent de la imatge.

##### 4.1.2.2 Non-Local Means Denoising

Per fer la implementació del *denoising* amb processament d'imatge, el model [7] fa ús dels píxels veïns per a recalcular els valors dels píxels i així reduir el soroll.

Les imatges resultants han estat extretes mitjançant l'ús de la demo funcional de l'article [7], amb una  $\sigma$  estàndard de 4 pel conjunt de les imatges.

## 4.2 Mètriques utilitzades

Per tal d'avaluar els mètodes de manera objectiva i equitativa es necessiten decidir les diferents mètriques a les quals seran sotmeses les imatges resultants dels diferents models. Les mètriques ens permetran obtenir els models amb millors resultats per cada tipus d'imatge. És per això que s'ha de realitzar una bona documentació cada una d'elles, ja que a l'entendre que estan avaluant específicament podrem saber on destaquen en general cada un dels models.

Podem trobar dos tipus principals de mètriques utilitzades per a analitzar la millora d'imatges.

#### 4.2.1 Referenciades

Són aquelles mètriques que necessiten d'un *ground truth* per a ser avaluades. La imatge aconseguida es compara amb la imatge *ground truth* i a partir de la comparació obtenim la qualitat de la imatge. Les mètriques solen ser fàcils de computar, però necessiten d'una imatge de referència. Algunes de les més destacades són [8]:

- IMMSE (*Mean-squared error*)
- PSNR (*Peak signal-to-noise ratio*)
- SSIM (*Structural similarity index*)

A causa del fet que la intenció del projecte és analitzar imatges reals per posar a prova als algorismes que s'han implementat, aquest tipus de mètriques no ens són útils. Tanmateix, durant el desenvolupament del projecte ha sorgit una idea per tal de poder-les usar.

La idea és imitar el comportament de les càmeres antigues per tal de poder generar les nostres pròpies imatges sense dependre de la seva antiguitat. Un mètode portar-ho a terme és fer ús de càmeres que imprimeixen al moment la imatge. Aquest tipus de càmeres utilitzen productes químics per imprimir les imatges, imitant el comportament de revelació de les imatges antigues. Amb aquest tipus de càmeres, però, seguim sense tenir una versió digital de la imatge, i tot i que es podria intentar replicar-la amb format digital fent la mateixa fotografia amb dispositius diferents, existeix una millor opció: un dispositiu que actua com a impressora d'aquest tipus de fotografies.



Figura 3: Imatge exemple del model Instax share sp-1

Funciona de la següent manera, envies una imatge digital a través de l'aplicació corresponent i el dispositiu la imprimeix usant el mateix format que el que usa la càmera. Concretament, es faria ús del dispositiu *Instax share sp-1* [9].

Per tal de digitalitzar les imatges un cop impreses s'ha fet ús d'una impressora convencional, concretament el model *HP envy 4527*. Durant aquest procés les imatges també patiran un empitjorament respecte a la seva versió física, fet que augmentarà més les diferències entre aquestes i la seva referència i farà més significatiu el treball dels models.

#### 4.2.2 No-Referenciades

No necessiten cap imatge de referència per funcionar, cosa que les fa perfectes per provar imatges pel nostre model. D'altra banda, aquestes mètriques són més difícils de calcular i menys clares en la manera de valorar la qualitat de la imatge [10].

- BRISQUE (*Blind Image Spatial Quality Evaluator*)
- NIQE (*Natural Image Quality Evaluator*)
- PIQE (*Perception based Image Quality Evaluator*)

Són les que s'utilitzaran majoritàriament per analitzar la qualitat de les imatges dins del nostre projecte.

#### 4.3 Selecció d'imatges

Pel desenvolupament del projecte es necessita fer una tria de les imatges que s'empraran per avaluar els diferents models. Seran imatges antigues que hagin estat digitalitzades, i serà important tenir diferents escenaris dins la mostra d'imatges per ser possible l'extracció de conclusions pel que fa a en quins models funcionen millor i trobar el model que millor sigui capaç de generalitzar d'entre tots ells. Una

altra idea a tenir en compte a l'hora de fer la tria de les imatges consisteix en trobar *challenging scenarios*; imatges que portin a l'extrem els models utilitzant imatges molt danyades, amb molts detalls o grans contrastos.

Per aquesta primera versió del codi, s'ha triat un conjunt de quatre imatges, únicament per a l'execució d'aquesta primera versió del projecte, el conjunt serà ampliat més endavant i és possible que algunes de les imatges siguin reemplaçades per altres més interessants.



Figura 4: Primer conjunt d'imatges triades.

En la figura 4 es mostra el conjunt seleccionat per la primera versió del codi.

Per la implementació de les imatges referencials s'ha seguit el procediment descrit a la secció 4.2.1, amb el qual s'ha construït un conjunt de 9 imatges amb les seves respectives referències tal com es mostra a la figura 5.



Figura 5: Mostra del conjunt d'imatges referencials.

Finalment, s'ha fet una tria del conjunt d'imatges finals amb les quals es provaran els diferents models mencionats a l'apartat 4.1. Per tal de provar els màxims mètodes possibles i assegurar una diversitat en la tria d'imatges s'han definit diferents escenaris amb el seu subconjunt d'imatges.

##### 4.3.1 Escala de grisos

El primer escenari definit es tracta d'imatges antigues en blanc i negre obtingudes de la font [11]. Es vol provar la millora de qualitat en imatges en escala de grisos, així com l'impacte de la colorització en aquesta.

Per a provar aquest escenari s'usaran els models *Bringing Old Photos Back To Live* i *DeOldify*. La imatge resultant de cadascun d'ells és molt diferent. El primer realitza una



millora de la imatge, però sense afegir-hi color, en canvi, el segon basa la millora en du a terme una colorització, passant d'una imatge en escala de grisos a una imatge a color. Els models lineals han estat descartats d'aquest escenari ja que el *color enhancement* és incapaç de treballar amb escala de grisos. A la figura 6 podem trobar un exemple.



Figura 6: Exemple del conjunt de imatges del escenari 1. Cada una amb la imatge antiga i una colorització manual.

A més a la font [11] ens proveeix d'una imatge exemple de colorització manual que usarem principalment per a fer una comparació amb la generada pel *DeOldify*.

Amb aquest subconjunt d'imatges es pretén establir la importància del color en les imatges segons les mètriques utilitzades, així com l'eficàcia en la colorització d'un model *deep-learning* respecte a un procés manual.

#### 4.3.2 Soroll elevat

La característica principal del subconjunt d'imatges [12] de l'escenari és l'elevat nivell de soroll. Altres de les característiques que es poden trobar són nivell major de detall, colors apagats o poc vius i contrast poc definit.

En aquest cas es tractaran sempre amb imatges a color, i s'analitzaran dos resultats. El primer generat amb el model *Bringing Old Photos Back To Live*, i el segon amb una combinació del *denoising* de *MirNet* i el *color enhancement* lineal de *IPOL*. S'ha canviat el *denoising* lineal utilitzat anteriorment pel del *MirNet* principalment degut a que generava millors resultats, i es podia seguir analitzant el component de processat lineal a través del *color enhancement*.

L'objectiu d'aquest escenari és l'anàlisi de la millora en situacions més variades, i per tant, quin dels mètodes usats és capaç de realitzar una millor generalització en les imatges.

#### 4.3.3 Imatges retrat

L'escenari és molt semblant a l'anterior, per això s'utilitzaran els mateixos models per la seva avaluació. La principal característica del subconjunt d'imatges és que apareixen en totes elles cares de persones a diferents distàncies i perfils.

El que es vol analitzar és el funcionament del *face detection* del model *Bringing Old Photos Back To Live*. Es compararà amb els resultats del segon mètode per establir si el *face enhancement* ha realitzat una millora substancial en la

qualitat de la imatge.



Figura 7: Exemple del conjunt de imatges del escenari 3.

## 4.4 Resultats

En el present apartat s'analitzaran els resultats que s'extreguin de la comparació de models. Per tal d'avaluar la qualitat de les diferents imatges, s'ha desenvolupat un codi en *matlab*, on li passem les imatges extretes dels diferents models i calculem les diferents mètriques per cada una de les diferents imatges.

Per la primera versió del codi s'han calculat les principals mètriques no referencials BRISQUE, NIQE i PIQE.

| Imatge 1 |              |              |              |       |             |       |
|----------|--------------|--------------|--------------|-------|-------------|-------|
|          | old          | m1           | m2           | m3    | m2+m3       | m3+m2 |
| BRISQUE  | 27,13        | <b>7,82</b>  | 20,34        | 24,84 | 26,11       | 23,47 |
| NIQE     | 3,49         | 3,77         | 2,89         | 2,67  | <b>2,32</b> | 2,59  |
| PIQE     | 17,82        | <b>14,17</b> | 21,90        | 36,66 | 22,77       | 33,77 |
| Imatge 2 |              |              |              |       |             |       |
|          | old          | m1           | m2           | m3    | m2+m3       | m3+m2 |
| BRISQUE  | <b>11,14</b> | 14,73        | 13,33        | 28,94 | 28,78       | 23,29 |
| NIQE     | 2,57         | 4,34         | 2,71         | 2,54  | <b>2,17</b> | 2,42  |
| PIQE     | <b>16,87</b> | 17,10        | 25,45        | 44,77 | 25,62       | 42,33 |
| Imatge 3 |              |              |              |       |             |       |
|          | old          | m1           | m2           | m3    | m2+m3       | m3+m2 |
| BRISQUE  | 30,76        | 25,42        | <b>17,91</b> | 41,40 | 22,25       | 43,09 |
| NIQE     | 3,41         | 4,27         | 2,96         | 3,29  | <b>2,45</b> | 3,15  |
| PIQE     | 15,33        | <b>11,51</b> | 17,13        | 52,78 | 28,87       | 49,64 |
| Imatge 4 |              |              |              |       |             |       |
|          | old          | m1           | m2           | m3    | m2+m3       | m3+m2 |
| BRISQUE  | 22,54        | <b>20,60</b> | 25,11        | 35,28 | 33,91       | 33,90 |
| NIQE     | <b>2,38</b>  | 3,55         | 2,81         | 2,85  | 2,59        | 2,85  |
| PIQE     | 22,83        | <b>20,92</b> | 24,62        | 61,89 | 52,89       | 60,84 |

Taula 1: Taula de resultats del conjunt d'imatges. m1 = model 4.1.1.1, m2 = IPOL denoising i m3 = IPOL color enhancement

Els mètodes utilitzats en aquest cas han estat els anomenats a l'apartat 2.1, però es va considerar una bona idea realitzar una combinació dels mètodes de processament d'imatge. L'objectiu de la combinació era reforçar ambdós mètodes de tal manera que el *color enhancement* aconseguís millorar els colors apagats propis d'aquest tipus d'imatges i el *denoising* reduís el soroll de la imatge i millores la seva nitidesa.

Amb els resultats extrets de la taula 1 podem extreure

|         | IMMSE          |                |         | PSNR         |              |       | SSIM        |      |             |
|---------|----------------|----------------|---------|--------------|--------------|-------|-------------|------|-------------|
|         | old            | m1             | m2      | old          | m1           | m2    | old         | m1   | m2          |
| img 1   | <b>2094,83</b> | 2149,11        | 2309,14 | <b>14,91</b> | 14,81        | 14,49 | 0,23        | 0,37 | <b>0,45</b> |
| img 2   | <b>3008,23</b> | 3804,76        | 3418,89 | <b>13,35</b> | 12,33        | 12,79 | 0,40        | 0,42 | <b>0,42</b> |
| img 3   | <b>1169,25</b> | 1219,33        | 2353,57 | <b>17,45</b> | 17,27        | 14,41 | <b>0,35</b> | 0,25 | 0,27        |
| img 4   | <b>1726,86</b> | 1944,54        | 2510,21 | <b>15,76</b> | 15,24        | 14,13 | 0,14        | 0,11 | <b>0,30</b> |
| img 5   | <b>2506,61</b> | 2646,91        | 3061,56 | <b>14,14</b> | 13,90        | 13,27 | 0,12        | 0,13 | <b>0,20</b> |
| img 6   | <b>1633,31</b> | 1640,44        | 3474,36 | <b>16,00</b> | 15,98        | 12,72 | <b>0,36</b> | 0,33 | 0,34        |
| img 7   | <b>1223,77</b> | 1458,45        | 2608,10 | <b>17,24</b> | 16,49        | 13,97 | <b>0,33</b> | 0,29 | 0,30        |
| img 8   | 4465,50        | <b>4149,42</b> | 4769,10 | 11,63        | <b>11,95</b> | 10,52 | <b>0,25</b> | 0,24 | 0,24        |
| img 9   | <b>1565,59</b> | 1788,02        | 2188,68 | <b>16,18</b> | 15,61        | 14,73 | 0,61        | 0,65 | <b>0,68</b> |
| mitjana | <b>2154,88</b> | 2311,22        | 2965,96 | <b>15,18</b> | 14,84        | 13,45 | 0,31        | 0,31 | <b>0,36</b> |
| medina  | <b>1726,86</b> | 1944,54        | 2608,10 | <b>15,76</b> | 15,24        | 13,97 | <b>0,33</b> | 0,29 | 0,30        |

Taula 2: Resultats de les imatges referenciades. m1 = model 4.1.1.1, m2 = IPOL denoising + IPOL enhancement

algunes conclusions. En primer lloc, hem de tenir en compte que les mètriques usades representen un valor més baix per imatges amb millor qualitat, i que tenen un valor entre el 100 i el 0. Podem observar, també, que la mètrica NIQE dona sempre un valor significativament inferior a les altres mètriques, fet que ajusta molt el marge de millora.

El mètode que millors resultats assoleix en els diferents escenaris és el primer corresponent amb el model *deep-learning*. Ha obtingut una millora del 71,17% respecte a l'original en la primera imatge, sent el mètode amb percentatge de millora més elevat.

En analitzar el comportament del mètode 3, corresponent al *denoising* amb processament d'imatge, podem veure com en imatges molt sorolloses pot servir per millorar lleugerament la seva qualitat. No obstant, en la majoria de casos, el *denoising* mostra un empitjorament respecte a la imatge original. Principalment, en realitzar el mètode amb imatges amb poc soroll es generen imperfeccions que li resten qualitat, tal com es mostra en la figura 8. Un altre dels factors claus d'aquest empitjorament és el fet de què en dur-se a terme el *denoising*, s'eliminen de la imatge alguns detalls i contrastos.



Figura 8: Imatge 3 retocada amb el mètode de denoising. Ampliació de zona amb imperfeccions.

Pel que fa a l'anàlisi de la combinació d'ambdós mètodes de processament d'imatge, veiem que empitjora en la majoria de les mètriques a excepció del NIQE, on la

combinació *enhancement* + *denoising* assoleix alguns dels millors resultats.

Podem observar en la taula de resultats que la imatge 3 no millora amb cap dels models usats. Això es pot deure al fet que la imatge té colors molt clars i poc contrast entre els elements que la corresponen. Aquest tipus d'escenaris poden ser interessants per posar a prova els nostres models.

En últim lloc, cal destacar un cas concret on les mètriques BRISQUE i PIQE mostren una millora en la imatge pel primer model. No obstant això, en analitzar la imatge, podem veure que el mètode ha generat imperfeccions, mentre que els mètodes de processament d'imatge -tal com es mostra en la figura 9- tot i que no ofereixen una millora segons les mètriques, no en generen. Això ens indica que tot i que les mètriques ens donin una valoració de la qualitat de la imatge, poden passar per alt el fet que es conservi el contingut de l'original i, per tant, és sempre bona pràc-



Figura 9: Imatge 4 retocada. A dalt amb el model *deep-learning* i a baix amb el model de processament d'imatge. A la dreta visualitzar el contingut generat.

Tot seguit es farà una anàlisi dels resultats obtinguts en el conjunt d'imatges referencials. Abans d'anализar els resultats de les mètriques considerarem quines imperfeccions es detecten en les imatges que hem generat respecte a imatges antigues per les quals han estat dissenyats els

models.

En primer lloc, podem observar una clara pèrdua de resolució i de pèrdua de color entre la imatge de referència i la imatge impresa. Aquesta pèrdua ve donada principalment per la tecnologia amb la qual treballa la impressora, fent processos químics per a la impressió de la imatge, imitant el sistema de les càmeres antigues.

Un altre de les característiques comunes en totes les imatges és un patró d'imperficcions que es presenten com a ratlles horitzontals al llarg de la fotografia, com es mostra en la figura 10, a causa del mètode d'impressió de la mateixa.




Figura 10: Imatge generada amb ampliació a les imperfeccions.

Finalment, trobem una sèrie de completa pèrdua de píxels, mostrats com a punts blancs en la imatge, que aquest cop s'han produït en el procés de digitalització de la imatge impresa.

Els models provats en les imatges referenciades han estat el model 4.1.1.1 dels models *deep-learning* i el 4.1.2.1 dels de processament d'imatge, ja que en provar els mètodes centrats en el *denoising* empitjoraven significativament la imatge al no tenir un soroll molt elevat.



Figura 11: Ampliació de cara modificada erràticament pel primer model.

A l'analitzar els resultats obtinguts a la taula 2, observem valors molt elevats en els resultats del *immse*. Això ens indica que la imatge generada amb la impressió de la referència guarda molt poca correlació amb el seu *ground truth*, ja que aquesta s'ha generat mitjançant processos químics en lloc de sintèticament.

També podem observar clarament que les mètriques *immse* i *psnr* assoleixen un millor valor en les imatges antigues en la gran majoria de casos. Hem de tenir en compte que aquestes mètriques valoren a un gran nivell la semblança entre la imatge analitzada i la seva referència, però això no significa que els canvis realitzats no hagin aportat una millora a la imatge, sinó més aviat que no han aconseguit un canvi que els approximi a la seva referència.

Per altra banda, la mètrica *ssim*, té en consideració canvis de percepció estructural a l'hora d'avaluar la similitud entre les imatges. En aquest sentit, podem observar que el mètode d'*enhancement* per processament d'imatge assoleix en general uns millors resultats.

Es pot apreciar que el primer mètode du a terme canvis en la imatge per a la seva millora, aplicant un *face recognition*. Això fa que en cares poc definides o molt allunyades les modifiqui de forma erràtica i mal construïdes. Aquestes modificacions són un altre dels motius pels quals el model dona els pitjors resultats en les imatges referenciades. A la figura 11 podem veure un exemple.

| Escenari 1 |             |              |             |              |
|------------|-------------|--------------|-------------|--------------|
| mitjana    |             |              |             |              |
|            | old         | m1           | m2          | manual       |
| BRISQUE    | 22,79       | 18,98        | 25,34       | <b>18,70</b> |
| NIQE       | 2,21        | 3,87         | 2,31        | <b>2,02</b>  |
| PIQE       | 26,12       | <b>17,53</b> | 23,06       | 22,76        |
| mediana    |             |              |             |              |
|            | old         | m1           | m2          | manual       |
| BRISQUE    | 20,01       | 19,06        | 23,07       | <b>18,20</b> |
| NIQE       | <b>2,31</b> | 3,77         | 2,42        | 2,33         |
| PIQE       | 25,04       | <b>20,65</b> | 22,58       | 25,18        |
| Escenari 2 |             |              |             |              |
| mitjana    |             |              |             |              |
|            | old         | m1           | m3          |              |
| BRISQUE    | 26,71       | <b>22,69</b> | 30,00       |              |
| NIQE       | 4,54        | 3,57         | <b>2,81</b> |              |
| PIQE       | 28,95       | <b>19,98</b> | 30,41       |              |
| mediana    |             |              |             |              |
|            | old         | m1           | m3          |              |
| BRISQUE    | 26,87       | <b>20,37</b> | 29,00       |              |
| NIQE       | 4,42        | 3,56         | <b>2,91</b> |              |
| PIQE       | 31,07       | <b>22,69</b> | 32,14       |              |
| Escenari 3 |             |              |             |              |
| mitjana    |             |              |             |              |
|            | old         | m1           | m3          |              |
| BRISQUE    | 34,77       | <b>17,60</b> | 23,73       |              |
| NIQE       | 3,84        | 4,02         | <b>2,41</b> |              |
| PIQE       | 29,95       | <b>18,64</b> | 24,70       |              |
| mediana    |             |              |             |              |
|            | old         | m1           | m3          |              |
| BRISQUE    | 29,30       | <b>17,30</b> | 20,66       |              |
| NIQE       | 4,02        | 4,07         | <b>2,62</b> |              |
| PIQE       | 31,56       | <b>19,05</b> | 23,87       |              |

Taula 3: Resultats finals en els diferents escenaris. m1 = model 4.1.1.1, m2 = DeOldify i m3 = MirNet denoising + IPOL enhancement





Figura 12: Visualització dels resultats obtinguts per la imatge 5. Les imatges d'esquerra a dreta corresponen a la imatge antiga, les imatges retocades amb el primer mètode deep-learning, el model d'enhancement i per últim la imatge de referència.

Per acabar, farem una anàlisi dels resultats de les mètriques pel conjunt total de les imatges en cada un dels diferents escenaris. Com aquests compten amb un volum de dades considerablement major la taula 3 mostra el valor de la mitjana i la mediana.

Al revisar els resultats de l'escenari 1, podem observar primerament que dels dos models provats, el que obté millors resultats en dues de les tres mètriques, és el *Bringing Old Photos Back To Live*. En canvi, el mateix model assoleix els pitjors resultats en la mètrica NIQE.

Si analitzem les dades del procés de restauració manual ens trobem que aquest aconsegueix les millors mètriques tant en el BRISQUE com en el NIQE, cosa que no és sorprenent, ja que és un procés personalitzat per a cada imatge i molt costós.

Podem concloure que la mètrica PIQE dona poca importància al color a l'hora d'analitzar la qualitat de la imatge, puix que ha assolit millors resultats una imatge en escala de grisos que a una a color processada manualment. Les altres dues mètriques si semblen donar un valor més rellevant al color en la imatge.

Un altre de les conclusions que podem extreure és que el model *DeOldify* fa una colorització no massa bona en la imatge, produint en la majoria de casos una empitjora i distanciant-se molt dels resultats de la colorització manual.



Figura 13: Visualització dels resultats de l'escenari 3. Les imatges d'esquerra a dreta corresponen a la imatge antiga, el model *Bringing Old Photos Back To Live* i *MirNet denoising + IPOL enhancement*.

Els resultats de l'escenari 2 ens mostren un millor rendiment en el primer model deep-learning. Això ens indica

que és més capaç de generalitzar en la millora de les imatges. Podem observar una diferència significativa entre els resultats d'aquest escenari i els de l'escenari 3 en les mètriques BRISQUE i PIQE. Els resultats d'aquestes ens mostren una millora pràcticament del doble en l'escenari 3 mentre que en el 2 es milloren en poc més del 20%.

Tal com es mostra en la figura 13, el model millora la definició de les cares. També cal destacar que el *face enhancement* realitza una millora en cares ben definides i imatges de bona resolució; tanmateix, amb cares molt allunyades en la imatge o imatges amb molt baixa resolució les cares es modifiquen erròniament arribant a generar empitjorament en el resultat.

De les diferències entre la mitjana i mediana entre algunes de les mètriques es pot inferir que la nostra mostra no té una distribució simètrica. Els casos (PIQE), on la mediana és significativament més gran que la mitjana, indiquen que els resultats de les imatges solen ser més elevats als de la mitjana i algun obtenen valors menors que la redueixen.

## 5 CONCLUSIONS

En examinar el comportament dels models en els diferents escenaris que han sigut provats, podem arribar a un seguit de conclusions.

El procés de millora d'imatges antigues és una tasca de complexitat molt elevada. És per això que és realment complicada una generalització d'un model per tots els escenaris diferents. A causa d'això trobem mètodes eficaços, però enfocats a un sol aspecte de la millora. Així i tot, hem pogut comprovar que és possible una generalització força elevada amb un únic model amb bons resultats. Una de les pràctiques que també han demostrat donar bons resultats és la suma de diferents mètodes singularitzats en aspectes diversos per a l'obtenció d'un resultat globalitzat, tenint l'avantatge de poder ser adaptat a diferents tipus d'imatge amb més facilitat.

En l'estudi d'imatges referencials descobrim un rendiment millor per part de l'enhancement lineal, pel fet que aquest realitza millores a la imatge sense modificar significativament el contingut d'aquesta i, per tant, assimilant-se més a la referència. A més descobrim que el tipus d'imatge

que es genera en aquest escenari difereix de les imatges per les quals el model ha estat entrenat, generant canvis molt poc significatius al ser aplicat. Una idea per la millora del seu rendiment seria entrenar les últimes capes del model per un millor funcionament les imatges referencials.

En canvi, en analitzar el comportament en les imatges no-referencials trobem que el model 4.1.1.1 obté uns millors resultats en la majoria de casos, mostrant molta adaptabilitat a les diferents imatges i escenaris.

Finalment, s'ha conclòs que així com la millora d'imatges és una tasca complexa, també ho és l'avaluació matemàtica de la qualitat d'una imatge. Tot i que en termes generals els resultats de les mètriques i les d'un observador humà coincideixen, s'han descobert casos on no ha estat així, especialment en les imatges no-referencials que no tenen manera de mesurar la conservació dels elements de la imatge antiga.



Figura 14: Visualització dels resultats obtinguts per la imatge 1. Les imatges d'esquerra a dreta corresponen a la Imatge original. Les Imatges retocades amb el primer mètode deep-learning, color enhancement, denoising, combinació enhancement+denoising, combinació denoising+enhancement

## 6 Annex

| Activitat                                        | 07-13 Març | 14-20 Març | 21-27 Març | 28-03 Març | 04-10 Abril | 11-17 Abril | 18-24 Abril | 25-01 Abril | 02-08 Maig | 09-15 Maig | 16-22 Maig | 23-29 Maig | 30-05 Maig | 06-12 Juny |
|--------------------------------------------------|------------|------------|------------|------------|-------------|-------------|-------------|-------------|------------|------------|------------|------------|------------|------------|
| Cerca de models deep-learning                    |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Cerca de models de processament d'imatge         |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Implementació de models deep-learning            |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Implementació de models de processament d'imatge |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Selecció imatges no-referencials                 |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Selecció/ preparació imatges referencials        |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Documentació informe de seguiment I              |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Documentació informe de seguiment II             |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Documentació informe final                       |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Desenvolupament de codi avaluatiu                |            |            |            |            |             |             |             |             |            |            |            |            |            |            |
| Anàlisi dels resultats obtinguts                 |            |            |            |            |             |             |             |             |            |            |            |            |            |            |

Taula 4: Diagrama de Grantt de projecte.

## 7 REFERÈNCIES

- [1] Syed Waqas Zamir, Aditya Arora, Salman Khan, Munawar Hayat, Fahad Shahbaz Khan, Ming-Hsuan Yang, Ling Shao, *Learning Enriched Features for Real Image Restoration and Enhancement*. University of California, Merced, USA, pp. 1-3, disponible a <https://paperswithcode.com/paper/learning-enriched-features-for-real-image>, 8 Jul 2020.
- [2] Christian Ledig, Lucas Theis, Ferenc Huszar, Jose Caballero, Andrew Cunningham, Alejandro Acosta, Andrew Aitken, Alykhan Tejani, Johannes Totz, Zehan Wang, Wenzhe Shi, *Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network*, pp. 1-2, disponible a <https://paperswithcode.com/paper/bringing-old-photos-back-to-life>, 25 May 2017.
- [3] Zi-Yu Wan, Bo Zhang, Dong-Dong Chen, Pan Zhang, Dong Chen, Jing Liao, Fang Wen, *Bringing Old Photos Back to Life*. University of Science and Technology of China, pp. 1-2, disponible a <https://paperswithcode.com/paper/bringing-old-photos-back-to-life>, 20 Apr. 2020.
- [4] Jantic, *DeOldify*, disponible a <https://github.com/jantic/DeOldify>, 24 Jan 2020.
- [5] Syed Waqas Zamir, Aditya Arora, Salman Khan, Munawar Hayat, Fahad Shahbaz Khan, Ming-Hsuan Yang, and Ling Shao, *Learning Enriched Features for Real Image Restoration and Enhancement*, pp. 1- 3, disponible a <https://paperswithcode.com/paper/learning-enriched-features-for-real-image>, 8 Jul 2020.
- [6] Pascal Getreuer, *Automatic Color Enhancement (ACE) and its Fast Implementation*, pp. 267 - 269, disponible a [https://www.ipol.im/pub/art/2012/g-ace/?utm\\_source=doi](https://www.ipol.im/pub/art/2012/g-ace/?utm_source=doi), 06 Nov 2012.
- [7] Antoni Buades, Bartomeu Coll, Jean-Michel Morel, *Non-Local Means Denoising*, pp. 209 - 210, disponible a [http://www.ipol.im/pub/art/2011/bcm\\_nlm/](http://www.ipol.im/pub/art/2011/bcm_nlm/), 13 Sep 2011.
- [8] *Instax Share SP-1 Manual*, pp. 1-2, disponible a [https://www.fujifilm.com.mx/productos/fotografia/instax/instax\\_impresoras/instax\\_share\\_sp\\_1/#vistageneral](https://www.fujifilm.com.mx/productos/fotografia/instax/instax_impresoras/instax_share_sp_1/#vistageneral), 2013
- [9] *HP envy 4527 Manual*, pp. 2, disponible a <https://media.flixcar.com/f360cdn/HP-1871666648-4aa6-5627ese.pdf>, Febrer 2017
- [10] *Image Quality Metrics*, MathWorks Documentation, disponible a <https://www.mathworks.com/help/images/image-quality-metrics.html>, 2020.
- [11] Greta Jaruševičiūtė, *116 Of The Oldest Color Photos Showing What The World Looked Like 100 Years Ago*, disponible a [https://www.boredpanda.com/first-color-photos-vintage-old-autochrome-lumiere-auguste-louis/?utm\\_source=google&utm\\_medium=organic&utm\\_campaign=organic](https://www.boredpanda.com/first-color-photos-vintage-old-autochrome-lumiere-auguste-louis/?utm_source=google&utm_medium=organic&utm_campaign=organic), 2018
- [12] Lina D, *20 Historic Black and White Pictures Restored in Color (Part II)*, disponible a <https://www.boredpanda.com/colorized-history-black-and-white-pictures-restored-in-color/>, 2014