UAB
Universitat Autònoma de Barcelona

Dipòsit digital de documents de la UAB

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

Madrigal Cárdenas, Óscar Miguel. *Compressió de dades satelitals utilitzant tècniques basades en IA*. Treball de Final de Grau (Universitat Autònoma de Barcelona), 2026 (Enginyeria Informàtica)

This version is available at https://ddd.uab.cat/record/334371

under the terms of the CC BY-SA license.

Compressió de dades satel·litals utilitzant tècniques basades en IA

Óscar Miguel Madrigal Cárdenas

Juny 2026

Resum– Aquest projecte adapta la xarxa neuronal R2-Net per comprimir imatges satel·litals multiespectrals. L'estudi compara la compressió per bandes individuals enfront d'un enfocament multibanda per demostrar que la redundància interbanda redueix l'entropia. Emprant normalització bloc a bloc i regularització L2 per estabilitzar el procés, els resultats validen la viabilitat d'aquesta arquitectura, assolint taxes de compressió de fins al 69%. Es confirma que el model multibanda optimitzat genera compressions més eficients que el tractament aïllat, postulant l'overfitting de xarxes neuronals com una alternativa viable als estàndards de compressió espacial clàssics.
Paraules clau– Compressió d'imatges, L'R2-Net, Xarxa neuronal, Dades satel·litals, Overfitting, Imatges multiespectrals.

Abstract– This project adapts the R2-Net neural network to compress multispectral satellite imagery. The study compares individual band compression against a multiband approach to demonstrate that interband redundancy reduces entropy. By employing block-by-block normalization and L2 regularization to stabilize the process, the results validate the viability of this architecture, achieving compression rates of up to 69%. The findings confirm that the optimized multiband model yields more efficient compression than isolated band processing, establishing neural network overfitting as a viable alternative to classical spatial compression standards.
Index Terms– Image compression, R2-Net, Neural network, Satellite data, Overfitting, Multispectral images.

1 Introducció i context

Les imatges obtingudes dels diversos satèl·lits existents proporcionen informació molt valuosa i precisa per a diferents àmbits relacionats amb la superfície terrestre. S'utilitzen en el dia a dia per funcions de gran importància com la meteorologia, l'agricultura o l'estudi dels oceans, entre d'altres.

• E-mail de contacte: Oscar.Madrigal@uab.cat
• Menció: Tecnologies de l'informació
• Treball tutoritzat per: Joan Bartrina Rapesta
• Curs 2025/26

Satèl·lits com els Sentinel, el Landsat o el Meteosat capturen cada dia multitud d'imatges de tot el planeta amb una precisió excel·lent. Aquestes imatges, però, solen tenir dimensions molt grans a causa de la **gran quantitat de dades que contenen**. Estan compostes per diverses bandes, en funció del tipus d'informació que cal representar i de les característiques de cada satèl·lit. És aquí on sorgeix la necessitat de comprimir aquestes imatges per a un tractament més versàtil i dinàmic de les dades.

En aquest projecte s'explorarà la compressió

d'aquestes imatges amb la xarxa neuronal R2-Net[1]. L'R2-Net és una xarxa neuronal totalment connectada (FC-NN) que s'entrena en línia, és a dir, actualitzant els seus paràmetres en temps d'execució. Aprofita l'*overfitting* —problemàtica molt freqüent a l'àmbit de les xarxes neuronals— i canvia el plantejament habitual d'aquestes xarxes, prioritzant la predicció eficient d'imatges individuals davant de la capacitat de generalització amb múltiples. Aquesta xarxa neuronal ja ha estat posada a prova amb imatges habituals, presentant uns resultats molt positius[1].

El seu funcionament consta d'una predicció intrabloc que genera un senyal d'error residual altament optimitzat, el qual esdevé la clau per a la reducció de l'espai d'emmagatzematge.

2 Objectius

Els objectius d'aquest projecte es conformen per l'anàlisi i adaptació del codi Python complet per a la **compressió d'imatges satel·litals mitjançant L'R2-Net**. Aquesta adaptació s'ha dividit en:

- **Estudi de la normalització**: es farà una recerca detallada dels mètodes de normalització eficients per al tractament d'aquestes imatges en el flux d'aprenentatge d'aquesta xarxa neuronal.
- **Adaptació per bandes individuals**: s'adaptarà el codi esmentat per a la predicció de les imatges separades per cada banda única.
- **Adaptació multibanda**: l'aprofitament de les bandes relacionades de les imatges serà l'aspecte clau en l'adaptació d'aquesta part.

L'adequació del codi tindrà com a finalitat provar certa la hipòtesi principal del projecte:

$$H_{x,y} > H_{x,y,z}$$

Aquesta vol demostrar que l'entropia resultant del senyal d'error obtingut del procediment complet de L'R2-Net per a l'adaptació banda a banda és major (i, per tant, menys eficient per a comprimir) que l'interbanda.

Es durà a terme una anàlisi minuciosa de l'adaptació i els resultats de cada part, a més de l'elaboració d'un codi executable per a la proposta més eficient.

3 Estat de l'art

En l'actualitat la compressió d'imatges multiespectrals és encara una problemàtica rellevant. Depenent de la captació del satèl·lit i de les seves condicions, la mida d'aquestes imatges pot anar des dels 500 MB de grandària fins a més d'1 GB, amb bandes individuals de 100 MB aproximadament. Això dona pas a una necessitat per reduir les mides d'aquestes imatges sense perdre, però, la gran precisió que representen les seves dades.

Aquesta necessitat s'ha abordat de maneres diferents al llarg del temps, amb mètodes basats en transformades matemàtiques per reduir la redundància de les dades de manera controlada. D'aquí provenen estàndards com el CCSDS 122.0-B o JPEG2000[2],[3].

El primer, establert pel comitè del mateix nom (Consultative Committee for Space Data Systems) és el principal referent en l'àmbit de les imatges satel·litals per bandes individuals; fa ús d'una transformada wavelet discreta (DWT) simple, dissenyada per les limitacions de processament del maquinari espacial[2]. Altrament, JPEG2000[3], tot i estar constituït també per la transformada *wavelet* discreta, s'ha establert fortament pel fet de destacar amb una escalabilitat superior en la resolució i qualitat de les imatges davant altres mètodes, conjuntament amb les funcionalitats avançades de les quals disposa com la descompressió progressiva o l'extracció de regions d'interès.

Tanmateix, aquests primers algorismes no estan dissenyats per treballar amb imatges multiespec-

trals o hiperespectrals, cosa que representa una limitació. Com a evolució, l'estàndard posterior CCSDS 123.0-B-2 ja va començar a implementar la predicció de les imatges fent ús de bandes prèviament processades en l'execució[4], però seguint un enfocament matemàtic tradicional. És precisament per superar aquestes barreres cap a on ha avançat la compressió d'imatges satel·litals i on entren en joc els mètodes d'aprenentatge profund i les **xarxes neuronals**. Aquestes ofereixen la capacitat d'aprendre distribucions estadístiques molt més complexes directament de les dades. En lloc de dependre de models predictius clàssics, l'ús d'arquitectures que exploten el *overfitting* temporal per a la predicció intrabloc —com és el cas de l'R2-Net— es presenta com una solució innovadora. Aquesta via d'investigació actual permet trencar el límit de generalització dels mètodes convencionals, prioritzant una predicció i compressió altament ajustada i eficient per a cada imatge individual.

4 Metodologia

Per l'assoliment dels objectius s'ha seguit una metodologia majoritàriament pràctica, sense deixar de banda les influències actuals ni la investigació.

Al llarg del projecte s'ha experimentat constantment amb el focus d'obtenir els millors resultats possibles a cada part del procediment.

4.1 Dades de prova utilitzades

Per l'elaboració i anàlisi del funcionament d'aquest projecte s'han obtingut una serie d'imatges del satèl·lit Sentinel-2. Aquest forma part del programa Copernicus, una iniciativa liderada per la Unió Europea amb l'Àgencia Espacial Europea (ESA) per oferir dades obertes i constants del planeta.

Per tal d'obtenir una visió completa de l'àrea d'estudi, s'ha treballat amb dues composicions de bandes de la mateixa imatge: una de parcial (*italia-5bands-20m.tif*) i una de completa (*italia-10bands-20m.tif*). Les característiques específiques d'ambdues composicions són les següents:

Taula 1: Especificacions de les bandes del satèl·lit Sentinel-2. Font: [5].

Banda	**Descripció**
B1	Aerosol costaner
B2	Blau
B3	Verd
B4	Vermell
B5	Red Edge 1
B6	Red Edge 2
B7	Red Edge 3
B8	NIR (Infraroig proper)
B8A	NIR estret
B9	Vapor d'aigua
B10	Cirrus (SWIR)
B11	SWIR 1 (Infraroig d'ona curta)
B12	SWIR 2

- **Composició parcial (*italia-5bands-20m.tif*):**
  - Dimensions: 5490×5490 píxels (resolució espacial de 20 m).
  - 16 bits de profunditat.
  - Bandes espectrals: 5 (B4, B5, B6, B7 i B8A).
  - Mida total: 574 MB (602.846.320 bytes).
- **Composició resolució espacial completa (*italia-10bands-20m.tif*):**
  - Dimensions: 5490×5490 píxels (resolució espacial de 20 m).
  - 16 bits de profunditat.
  - Bandes espectrals: 10 (B1, B2, B3, B4, B5, B6, B7, B8A, B11, B12)
  - Mida total: 1.2 GB (1.205.648.350 bytes).

4.2 Funcionament base de L'R2-Net

L'R2-Net (Reversible Regression Network) és una xarxa neuronal dissenyada específicament per a la predicció intrabloc d'imatges. El nucli de la seva eficiència rau en el *overfitting* directe a les dades, ja que l'objectiu en aquest àmbit no requereix en cap moment generalitzar el model cap a conjunts de dades externs. A escala arquitectònica i algorísmica, aquesta optimització es realitza completament en línia mitjançant l'ús de només dues iteracions de retropropagació a partir d'un sol vector de característiques com a entrada.

A escala estructural, el funcionament de L'R2-Net està dividit de manera simètrica en dues fases consecutives fonamentals: una fase de predicció, on s'infereixen els valors dels píxels per extreure'n el senyal d'error, i una fase de reconstrucció, dissenyada per recórrer el camí invers. Per evitar la necessitat de transmetre la configuració inicial de la xarxa, els seus paràmetres es defineixen prèviament amb valors fixos i coneguts. Així mateix, l'ocupació de funcions d'activació no lineals, concretament la funció Sigmoide, exigeix que tant els vectors d'entrada com els valors de referència estiguin estrictament normalitzats dins de l'interval [0, 1] per garantir la convergència de l'algorisme.

Finalment, la característica més important de L'R2-Net és la seva naturalesa reversible, la qual permet recuperar les dades originals de forma exacta exclusivament a partir del senyal d'error obtingut de la predicció. Això elimina per complet la necessitat d'emmagatzemar o transmetre els paràmetres apresos pel model durant el procés de generació del fitxer comprimit, optimitzant així el rendiment de la compressió.

4.3 Normalització

El fet de tractar amb imatges que poden arribar a una representació de fins a 16 bits comporta modificacions en el paradigma de normalització de les dades. Aquestes imatges presenten un rang de valors molt més ampli, imprescindible per poder representar-ho tot amb la màxima precisió[6].

La principal dificultat prové dels anomenats valors atípics o *outliers*, és a dir, píxels amb valors clarament allunyats de la resta. Sovint es deuen a errors i soroll, com ara interferències atmosfèriques en la transmissió, encara que també poden correspondre a valors reals derivats de condicions específiques de la zona captada[7]. En ambdós casos, aquests valors atípics desvien i distorsionen les mètriques de les imatges i poden afectar de manera significativa el procés de predicció posterior.

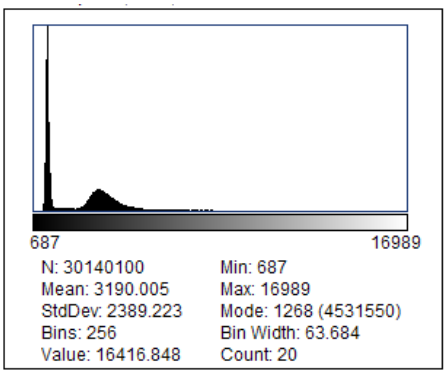

Figura 1: histograma de la banda 6 de italia-12bands-20m.tif

A causa d'això, el procés típic de normalització mitjançant els valors màxims i mínims de la imatge, per exemple, resulta ser ineficient. Arran d'aquesta problemàtica, s'han explorat i comparat diversos mètodes de normalització aplicats a les imatges:

- **Normalització bloc a bloc**: conjuntament amb la predicció intrabloc produïda en el procediment habitual de L'R2-Net, s'introdueix de manera prèvia una normalització segons el valor màxim de cada bloc B. Amb aquest valor màxim m es calcula:

$$b_{norm} = \frac{b}{m} \quad , \forall b \in B$$

on b correspon a un pixel qualsevol del bloc actual. Inicialment es va plantejar l'ús d'una normalització Min-Max local per a cada bloc en comptes de només segons el màxim, però els resultats experimentals han demostrat que aquesta estratègia empitjora notablement la qualitat de la reconstrucció. Això es deu a que en aplicar una normalització Min-Max independent per a cada bloc, el valor zero, que sovint representa zones de fons o sense dades i que les xarxes assimilen de manera molt eficient, es desplaça de forma arbitrària. Això destrueix la coherència de la imatge global, genera discontinuïtats a les fronteres entre blocs adjacents i amplifica artificialment el soroll.

- **Normalització lineal per percentils**: consisteix en el retallament i ajust global de valors tant per sota com per sobre d'uns llindars escollits prèviament. En el cas dels percentils 1%-99%:

$$p_{clip} = max(P_1, min(p, P_{99})) \forall p \in I$$

p representa un píxel de la imatge completa I. Amb el retallament, s'aplica la normalització:

$$p_{norm} = \frac{p_{clip} - P_1}{P_{99} - P_1}$$

Les prediccions resultants per ambdós mètodes generen posteriorment unes prediccions més precises que altres més globals o que no consideren les problemàtiques esmentades. Dels dos, així i tot, destaca en eficiència el mètode **bloc a bloc**; el fet de tractar els màxims per zones diferents de la imatge redueix considerablement l'impacte provocat pels valors atípics.

4.4 Adaptació del codi

L'ajust del codi Python original pels procediments de L'R2-Net per bandes múltiples (Figura 2) i individuals comporta diverses modificacions estructurals i funcionals en la seva arquitectura. Aquest difereix segons el seu funcionament esperat i la seva aplicació en un escenari real; a continuació s'especifica amb més detall.

El procediment està format per dues iteracions principals; per **bandes de la imatge i per blocs de cadascuna**. S'inicia aplicant primerament la normalització i seguidament el procés de predicció. La predicció de L'R2-Net rep com a parametres el *ground truth* del bloc actual, un multiplicador d'aprenentatge *learning rate* fixat pel procediment complet, i uns valors d'entrada x. Aquí ja varia segons l'adaptació; en el procediment per bandes individuals l'entrada del predictor només contindrà blocs adjacents a l'actual, mentre que al mètode multibanda també hi seran dades de bandes ja predites anteriorment. Un cop s'obté la predicció i es calcula el senyal d'error per totes les bandes es duu a terme la quantització i compressió de les dades. Amb això es pot finalitzar el procés, reconstruint el *ground truth* amb els senyals d'error rebuts. Aquesta és la secció més complexa computacionalment. La quantitat d'informació que rep com a entrada, conjuntament amb la mida de bloc escollida determina la major part de temps d'execució del codi.

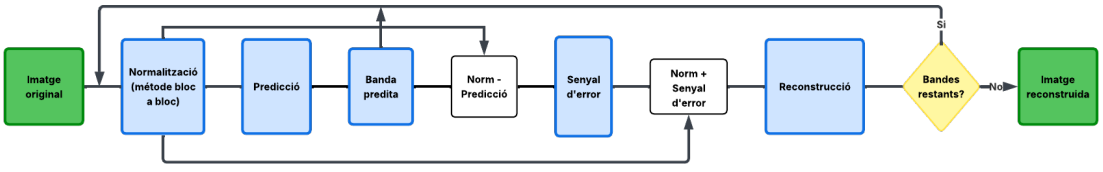

Figura 2: Flux del procediment complet de l'R2-Net adaptat per a imatges multibanda.

Amb el senyal d'error, conjuntament amb els valors màxims de cada bloc i les dimensions de la imatge, es quantitza per la seva posterior compressió. És aquí on es produeixen pèrdues d'informació en tenir lloc la conversió de variables en punt flotant a enters, encara que son insignificants, tractant-se així d'una **compressió Near-Lossless**.

El procés de reconstrucció rebrà el senyal d'error comprimit, conjuntament amb les dimensions generals de cada banda de la imatge i els valors màxims necessaris per desfer la normalització aplicada. Aquesta fase també difereix en cada implementació, ja que, per aconseguir la reconstrucció correcta, ha de fer tot el procediment invers a la predicció; si només va fer servir els blocs adjacents com entrada, la reconstrucció ho imita però amb els senyals d'error adients.

La fase de predicció és on han sorgit les majors limitacions i problemàtiques de l'adaptació. El nucli d'aquestes limitacions ve donat, de manera paradoxal, perquè **la predicció resultant es excel·lent en quant a precisió**. La xarxa s'ajusta a les dades de manera molt eficient. Això és encara més notori amb el mètode multibanda, obtenint un senyals d'errors on la gran majoria de valors son zeros i amb una mida comprimida insignificant. Conseqüentment, la reconstrucció de la imatge no es pot donar de manera correcta, arribant en casos a provocar errors en l'execució degut als diferents càlculs de la funció d'activació Sigmoide, o, en canvi, obtenint una qualitat de reconstrucció pobre. Per evitar això, s'han aplicat una sèrie de mesures de **regularització** al procediment.

L'ajust principal aplicat consisteix en una **normalització L2** [8] als valors propers ja predits que es faran servir a la pròxima predicció. Forçant l'entrada a que la seva longitud matemàtica sigui $\sqrt{2}$, s'afegeix més estabilitat general a la funció Sigmoide, impedint que els pesos de la xarxa creixin descontroladament buscant un ajust idoni. Així es sacrifica de manera controlada precisió a la predicció per continuar garantint la reversibilitat de la xarxa neuronal.

Aquesta mesura, tot i ser efectiva per la fase de predicció, al replicar-se a la reconstrucció no aconsegueix estabilitzar completament la Sigmoide inversa utilitzada en aquesta fase, resultant així en reproduccions d'una qualitat ineficient. Per aquesta raó i deguda la naturalesa de les imatges satel·litals, les quals requereixen d'una precisió molt elevada a les seves dades, s'ha aplicat una modificació addicional, amb l'objectiu d'aconseguir un equilibri entre compressió i reconstrucció en l'àmbit d'aquest treball.

La modificació esmentada consisteix en alterar els valors inicials de pesos (W) i biaix (b) a ambdues parts del procediment de 1 a 0. Amb això sí s'aconsegueix estabilitzar la inversa de la funció Sigmoide i millorar notablement la reconstrucció.

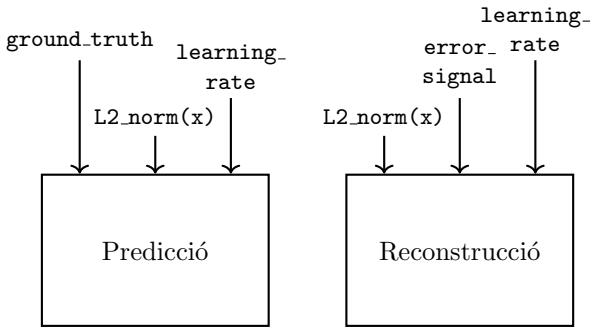

Figura 3: valors d'entrada dels procediments de predicció i reconstrucció.

Com es veurà a l'apartat de resultats, l'alteració d'aquests valors provoca també diferencies en l'aprenentatge de la xarxa per el procés de predicció dels diferents mètodes, però donen lloc a uns valors equilibrats.

4.5 Resolució espacial

Finalment, cal destacar l'impacte de les diferents resolucions espacials de les imatges satel·litals. Aquestes poden comportar la diferència més gran quant a temps d'execució total al procediment, i es poden beneficiar de mides de bloc més grans.

Taula 2: Resultats de las diferents configuracions de L'R2-Net per la imatge *italia-5bands-20m.tif*.

Mètode	**Entropia (bits/símbol)**	**Mida total arxiu comprimit (MB)**	**PSNR (dB)** (Predicció — Reconstrucció)				
			B4	**B5**	**B6**	**B7**	**B8A**
R2-Net banda individual amb normalització Min-Max	9.466	177.5	25.13 — 22.56	25.49 — 23.03	26.59 — 24.10	26.87 — 24.44	26.87 — 24.65
R2-Net banda individual amb normalització per percentils	9.982	187.8	25.23 — 23.74	25.49 — 23.20	26.55 — 22.95	26.88 — 22.93	27.04 — 23.02
R2-Net banda individual amb normalització bloc-bloc	11.282	224.98	29.25 — 37.73	28.72 — 37.37	28.35 — 36.71	28.43 — 36.43	28.25 — 36.26
R2-Net multibanda amb normalització bloc-bloc	11.282	224.98	29.25 — 105.30	28.72 — 104.82	28.35 — 104.13	28.43 — 103.72	28.25 — 103.68



Figura 4: imatge italia-b2-10m.tif amb resolució espacial de 10 metres. La seva resolució és de 10980x10980 píxels.

5 Resultats

Per l'obtenció dels resultats següents s'han fet les execucions amb una mida de bloc de 32×32 i *learning rate* de 0.5. Posteriorment en aquest apartat, es reflectirà com varien els resultats per diferents dimensions de bloc i *learning rates*.

Elaborant una comparativa entre els diferents mètodes de normalització i predicció (Taula 2), s'observa com la qualitat de la normalització per blocs és lleugerament superior a la resta de mètodes. La normalització per percentils no aconsegueix millorar a un Min-Max global, encara que funciona millor amb resolucions espacials de menor mida.

Tot i tenir una pitjor qualitat de predicció que els mètodes multibanda, la normalització Min-Max aconsegueix comprimir la imatge a 177.5 MB dels 574 MB inicials amb una taxa de compressió del **69%** aproximadament, respecte el **60%** d'ambdós mètodes amb normalització bloc a bloc. De manera lògica llavors, l'entropia obtinguda per el primer mètode es menor que la resta, separats per **uns 1.8 bits/símbol** de diferència.

A causa de la modificació dels pesos i el biaix inicials esmentada prèviament a la metodologia, la convergència de la xarxa a la fase de predicció es veu impactada, frenant l'aprenentatge enormement. Malgrat que això disminueix l'eficiència i la precisió de la predicció, és un compromís necessari per garantir una bona reconstrucció. Aquest empitjorament en la precisió predictiva dona com a resultat senyals d'error com els de la Figura 5, carregats d'informació.

Aquesta modificació, però, no es la causant de les baixes qualitats de reconstrucció obtingudes als mètodes per bandes individuals. En canvi, si dona lloc a la gran qualitat obtinguda al mètode multibanda. Per aquest mètode la xarxa aconsegueix estabilitzar el càlcul dels paràmetres locals de cada bloc gràcies a la informació simultània reconstruïda amb anterioritat. Això evita les inestabilitats matemàtiques que pateixen les bandes aïllades, especialment alhora de calcular la inversa de la funció d'activació en aquesta fase.

Com a conseqüència, s'obtenen diferencies de PSNR de reconstrucció de **fins 67 dB** respec-

te al tractament individual, com es el cas de la banda 4.

Tot i així, la hipòtesi proposada d'aquest projecte no es compleix, ja que s'obté una entropia equivalent per ambdós mètodes normalitzats bloc a bloc. Al següent apartat es mostra com la variació del *learning rate* permet complir finalment aquesta hipòtesi, encara que de manera alternativa.

5.1 Variació del *learning rate*

Modificar el *learning rate* global del procediment ha demostrat ser efectiu per afinar la qualitat de la predicció i la reconstrucció en l'enfocament multibanda, com es pot veure al gràfic de la Figura 6 amb la imatge completa *italia-10bands-20m.tif*.

Reduir aquest valor permet a l'aprenentatge de la predicció del mètode multibanda assolir una convergència més optima i precisa, resultant en compressions més eficients, encara que reduint la qualitat de les reconstruccions lleugerament.

En el cas de valors mínims de *learning rate* com 0.1, la mida final de compressió baixa als 347.88 MB, una reducció del **21%** respecte els 439.62 MB aconseguits amb el valor utilitzat fins ara, reduint això si, la qualitat de la reconstrucció a 91 dB aproximats dels 105 dB aconseguits amb un *learning rate* de 0.5. De manera contraria, valors més elevats comporten mides de compressió mes grans, però reconstruccions de major qualitat, com passa per exemple al cas *learning_rate* = 0.9, on s'arriba a un PSNR de 109.95 dB, amb una mida d'arxiu de 463.95 MB.

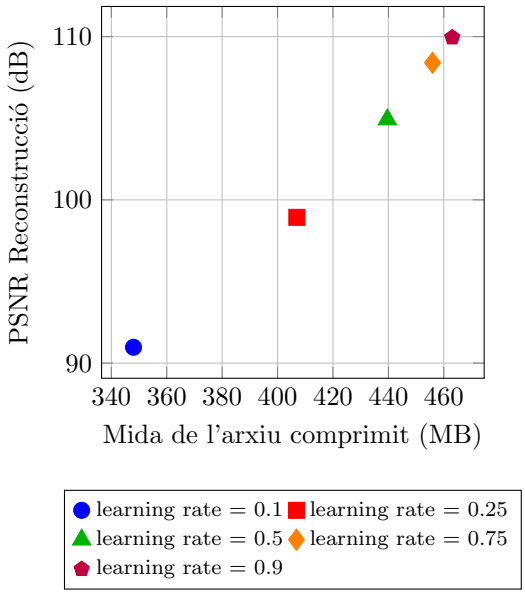

Figura 6: Comparativa del PSNR respecte a la mida de l'arxiu comprimit per a diferents valors de *learning rate*. al mètode Multibanda.

Minimitzant el *learning rate* com s'ha mostrat

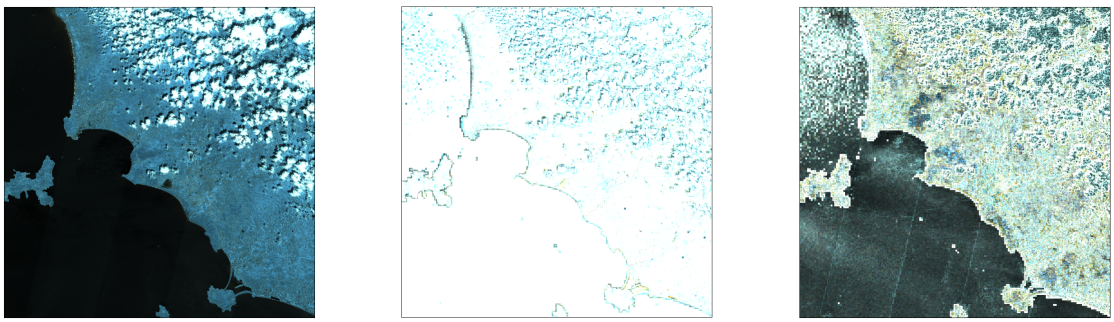

Figura 5: banda B5 de la imatge italia-5bands-20m.tif (esquerra) amb la predicció obtinguda (mig) i el senyal d'error corresponent (dreta).

redueix també l'entropia general de la compressió, provant com certa la hipòtesi del projecte, ja que aquestes variacions en l'aprenentatge de la xarxa **no produeixen cap afectació als mètodes per banda individual** esmentats.

5.2 Mides de bloc

Addicionalment, modificant les diferents dimensions de bloc, sense alterar el *learning rate* del procediment s'obtenen variacions menys dràstiques de compressió i reconstrucció, com es pot veure a la Figura 7, amb les dades de la imatge *italia-10bands-20m.tif* novament.

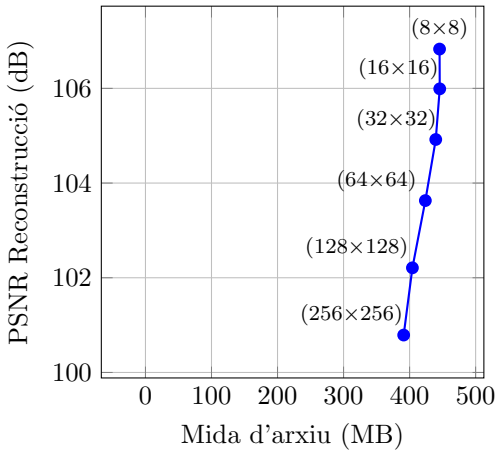

Figura 7: Relació entre la mida d'arxiu i el PSNR Reconstrucció per a diferents mides de bloc pel mètode Multibanda.

Per mides petites de bloc la compressió no millora, però la qualitat final no es veu afectada. Com més grans són els blocs, en canvi, s'obté una millor compressió, arribant als 391 MB amb blocs de 256×256, però el PSNR es veu lleugerament atenuat.

Aquest ajust, però, té major afectació en el temps d'execució global del procediment, especialment per imatges de major resolució espacial.

6 Conclusions

L'adequació de L'R2-Net per al tractament d'imatges satel·litals ha provat de ser més que viable, tant de manera multibanda com per bandes separades, especialment per la predicció d'aquestes.

S'ha constatat, però, que adaptar aquesta arquitectura requereix algunes solucions per tractar correctament les dades. Primerament, la normalització, on la millor alternativa és tractar-la bloc a bloc, com es fa amb la predicció. Seguidament la regularització de la xarxa, que aconsegueix que es mantingui la reversibilitat del procés. Aquesta regularització pot ser més o menys estricta. Com s'ha evidenciat al llarg del document, la seva visió s'ha centrat no només a obtenir una bona compressió, sinó també a garantir que la reconstrucció final presenti una qualitat elevada. Una possible alternativa a futur pot ser doncs la modificació d'aquesta regularització, prioritzant algun aspecte diferent de les imatges. També cal destacar de manera lògica no només la regularització, sinó continuar explorant aquesta via en cerca de millores o alternatives d'aquest tipus de xarxes neuronals aplicades a imatges satel·litals. Per últim, l'anàlisi computacional d'aquesta arquitectura és també de gran importància, ja que permetria considerar la seva implementació amb els mateixos satèl·lits, per exemple.

7 Agraïments

Agraeixo al meu tutor, Joan Bartrina Rapesta, pel seu suport i guia durant el desenvolupament del projecte, per les reunions setmanals per resoldre les diverses problemàtiques i dubtes apareguts, a més de la seva disponibilitat plena. Vull agrair també a la meva família, parella i amics la seva confiança en mi i el seu suport incondicional durant tot aquest temps. Per últim agrair també a la Universitat Autònoma de Barcelona per el seu bon tractament i ensenyament al llarg dels anys.

8 Ús de la IA generativa

La funcionalitat de la IA generativa en el marc de confecció d'aquest projecte queda limitada, d'una banda, en el suport en tasques d'edició i consulta ortotipogràfica durant el procés de redacció del treball. D'altra banda, també s'ha emprat Gemini per a la consulta de tecnicismes, a més de per a consultar funcionalitats del programari Fiji i QGIS.

Referències

[1] Victor Sanchez. Overfitted neural networks for block-based intra-prediction. In *Data Compression Conference Proceedings*, pages 13–22. Institute of Electrical and Electronics Engineers Inc., 2024.

[2] Consultative Committee for Space Data Systems. Image data compression. Recommended Standard CCSDS 122.0-B-2 EC 1, CCSDS, September 2017.

[3] Xiaqiong Yu, Jinxian Zhao, Tao Zhu, Qiang Lan, Lin Gao, and Lingzhi Fan. Analysis of jpeg2000 compression quality of optical satellite images. In *Proceedings - 2022 2nd Asia-Pacific Conference on Communications Technology and Computer Science, ACCTCS 2022*, pages 500–503. Institute of Electrical and Electronics Engineers Inc., 2022.

[4] Consultative Committee for Space Data Systems. Low-complexity lossless and near-lossless multispectral and hyperspectral image compression. Recommended Standard CCSDS 123.0-B-2, CCSDS, February 2019.

[5] European Space Agency. Sentinel-2 msi technical guide: Radiometric resolutions, 2026. [Data de consulta: 16 de juny de 2026].

[6] Qin Gao, Will Lewis, Chris Quirk, and Mei-Yuh Hwang. Technical report, 2011.

[7] Vinicius Alves De Oliveira, Marie Chabert, Thomas Oberlin, Charly Poulliat, Mickael Bruno, Christophe Latry, Mikael Carlavan, Simon Henrot, Frederic Falzon, and Roberto Camarero. Satellite image compression and denoising with neural networks. *IEEE Geoscience and Remote Sensing Letters*, 19, 2022.

[8] Elad Hoffer, Ron Banner, Itay Golan, and Daniel Soudry. Norm matters: efficient and accurate normalization schemes in deep networks. In S. Bengio, H. Wallach, H. Larochelle, K. Grauman, N. Cesa-Bianchi, and R. Garnett, editors, *Advances in Neural Information Processing Systems*, volume 31. Curran Associates, Inc., 2018.

9 Apèndix

A continuació a la Taula 1 d'aquesta secció es troben els resultats obtinguts dels diferents mètodes previs a la modificació de pesos i biaixos.

Taula 1: Resultats de las diferents configuracions de L'R2-Net per la imatge *italia-5bands-20m.tif* sense modificar W i b.

Mètode	**Entropia (bits/símbol)**	**Mida total arxiu comprimit (MB)**	**PSNR (dB)** (Predicció — Reconstrucció)				
			B4	**B5**	**B6**	**B7**	**B8A**
R2-Net banda individual amb normalització Min-Max	0.431	0.77	68.46 — 13.26	68.59 — 13.13	68.77 — 13.50	68.79 — 13.69	68.71 — 13.94
R2-Net banda individual amb normalització per percentils	0.692	1.49	64.69 — 16.36	56.94 — 16.01	56.19 — 15.84	58.85 — 15.74	59.52 — 15.70
R2-Net banda individual amb normalització bloc-bloc	0.069	0.75	85.01 — 28.73	85.70 — 28.77	83.99 — 29.57	88.74 — 29.39	88.51 — 29.54
R2-Net multibanda amb normalització bloc-bloc	0.019	0.63	85.01 — 27.44	143.87 — 22.21	147.42 — 23.26	149.69 — 22.55	149.85 — 21.94