

# Estudi d'optimització per a Regression Wavelet Analysis a través de models de regressió combinats

Ángel Martín Somé

**Resum**— Basant-nos en el treball realitzat al *paper Regression Wavelet Analysis for Lossless Coding of Remote-Sensing Data*, es presenta un aprofundiment en la matèria intentant trobar punts de millora en quant al rendiment de compressió o el cost computacional de la transformació. RWA utilitza implementacions de la Transformada *Wavelet* Discreta, concretament en aquest projecte només la implementada amb el filtre *Haar*, per dividir les dades en components d'aproximació i components de detall. Les components de detall, mitjançant diferents models de regressió, són posteriorment estimades a partir de les d'aproximació, evitant així la necessitat d'emmagatzemar el cent per cent de les primeres. La nova aproximació busca combinar els esmentats models i observar el seu comportament conjunt per investigar si es podrien incrementar encara més els beneficis de l'anàlisi de regressió a les transformades *Wavelet*.

**Paraules clau**— Wavelet, Haar, transformada, regressió, RWA, MATLAB, compressió de dades, transmissió, components espectrals, components espacials, satèl·lits, teledetecció, imatges, AVIRIS, Hyperion.

**Abstract**— Based on the work of *Regression Wavelet Analysis for Lossless Coding of Remote-Sensing Data*, a new approach is presented trying to introduce an improvement in matter on compress performance or computational cost. RWA uses implementations of the Discrete Wavelet Transform, in particular an implementation with the Haar filter, in order to divide data between approximation components and details components. Details components, through different regression models, are later estimated using the approximation components, avoiding that way, the necessity of storing all the data from the first ones. The new approach seeks to combine, all mentioned models and observe their integrated behavior trying to investigate if it is possible to increase even more the benefits of the Regression Wavelet Analysis.

**Index Terms**— Wavelet, Haar, transform, regression, RWA, MATLAB, data compression, data transmission, spectral components, special components, remote sensing, satellite, images, AVIRIS.



## 1 INTRODUCCIÓ

LES diverses agències espacials, governs i empreses privades dediquen cada any inversions molt elevades a l'observació de la Terra, que en bona part, es realitza mitjançant imatges de teledetecció obtingudes des de satèl·lits o des d'avions. Concretament, en aquest document es treballarà amb dades captades per dos sensors diferents: AVIRIS (*Airborne Visible/Infrared Imaging Spectrometer*) i Hyperion. Aquestes imatges permeten fer millors prediccions meteorològiques, una millor gestió del territori, una detecció eficient de zones en desforestació, d'incendis i desastres naturals entre altres aplicacions. Aquestes imatges acaben tenint una mida molt elevada que dificulta el seu emmagatzematge i la seva distribució. Per a pal·liar parcialment aquesta dificultat, s'utilitza la compressió de dades.

Existeixen dues formes de comprimir:

- Sense pèrdua (*Lossless*), on la informació que es recupera en descomprimir és exactament la mateixa que abans de comprimir bit a bit. Aquesta forma de compressió es molt útil per transmetre dades tipus comunament conegudes com "discretes", com per exem-

ple, documents de text, resultats de càlculs, arxius de bases de dades i imatges de caràcter científic o analític, com és el nostre cas [1].

- Amb pèrdua (*Lossy*), on s'elimina una part assumible de la informació per obtenir un conjunt de dades menor que l'inicial, però que representa la informació de manera útil. Aquest mètode de compressió és útil per imatges o arxius d'àudio i vídeo que poden ser reduïts mantenint el mateix aspecte per a l'humà que els visualitzi [2].

Nosaltres ens centrarem en un procediment *Lossless*. L'èxit d'aquesta compressió però, depèn de la quantitat d'informació redundat que es pugui eliminar per reduir la mida de les dades originals.

## 2 ESTAT DE L'ART

Es poden trobar diferents algorismes i sistemes de transformació que maximitzin de manera més o menys òptima l'aprofitament de la redundància.

Un dels procediments més coneguts, que en l'estudi

previ a aquest treball es va triar com a base comparativa, es la PCA (*Principal Component Analysis*) [3]. Aquest mètode recull la informació tridimensional que conformen les imatges i les expressa en dues noves components no relacionades entre elles, proporcionant la menor correlació teòrica possible entre les dades a treballar.




Fig. 1. Exemple de PCA sobre un conjunt de dades tridimensionals. La informació es presenta sobre dues noves components per ordre de prioritats, sent l'eix horitzontal la component amb més variació [4].

Aquestes propietats fan que la PCA sigui un mètode molt útil a l'hora de transformar per després comprimir imatges multiespectrals, on existeixen tres dimensions de no massa grandària, però quan es treballa amb imatges hiperespectrals, on la dimensió de profunditat pot arribar a tenir més de 8000 canals, com més endavant es detallarà, aquest sistema de transformació comença a ser massa costós computacionalment, encara que posteriorment, ofereixi el millor rendiment de compressió.

Per aquest motiu, aquest treball utilitza com a punt de partida una implementació de la DWT (*Discrete Wavelet Transform*) que proporciona un sistema de transformació espectral molt més simple computacionalment (Fig. 14). D'entre diverses conegudes implementacions com la 5/3 o la 9/7 [5] utilitzarem en concret la implementada amb el filtre *Haar*.

El procés que es segueix per utilitzar aquesta transformada, consisteix en reduir a la meitat el número de canals que contenen informació important sobre l'espectre a base de divisions entre parelles de components. A la primera meitat (H) s'emmagatzemen els quocients (components d'aproximació  $V(j)$ ) i a la segona meitat (G) s'emmagatzemen els residus de les operacions (components de detalls  $W(j)$ ) per poder recuperar la informació inicial. Aquesta reducció es pot executar tantes vegades com sigui necessària fins que només quedi un sol canal amb components d'aproximació. Partint de la base de que Haar pren les components de dos en dos, el nombre màxim d'iteracions o nivells venen delimitats per  $\log_2(z)$ , on  $z$  es el nombre de components espectrals. Posteriorment, podem recuperar la informació original al complet, ja que les operacions matemàtiques implicades són reversibles i operen amb nombres enters.




Fig. 2. Detall de l'algoritme DWT simple amb el filtre Haar sobre dos nivells de transformació. Els nivells de transformació aplicable estan definits per  $\log_2(z)$ , on  $z$  correspon al numero de nivells espectrals.

### 3 ALGORITME: REGRESSION WAVELET ANALYSIS

Arribats a aquest punt s'introdueix una innovadora millora per augmentar en gran mesura la capacitat de transformació, apropant-nos a valors de correlació propers als de PCA (0.0000). Es proposa la implementació de diferents models de regressió. Aquests models matemàtics implementaran diferents solucions per estimar les components de detall basades en les components d'aproximació que les DWT tradicional utilitzen. Aquesta aproximació ens permetrà enregistrar unes components de detall molt pròximes a zero amb la corresponent funció per estimar els seus valors originals i així reduir de manera molt significativa la quantitat de dades a emmagatzemar i tractar. A més, aquesta regressió s'executarà per cada nivell de transformació aplicat incrementant encara més la seva eficiència.

Per fer-ho, el sistema que es presenta en aquest treball s'anomena RWA (*Regression Wavelet Analysis*). Aquest sistema es basa en la premissa que les imatges captades per teledetecció no són una imatge corrent amb dues dimensions, és a dir, components espacials, sinó que tenen una tercera component anomenada component espectral que pot arribar a tenir fins a 8461 canals en el cas de les imatges captades pel sensor IASI. Cada un d'aquests canals és una imatge de  $1530 \times 60$  amb una profunditat de 16 bits el que implica que si el satèl·lit *MetOp*, on és muntat el sensor, fa 14 òrbites al dia, aquest està generant al voltant de 20Gb diaris.

El *paper* en el qual es basa aquest TFG [6] descriu i utilitza quatre tipus de models de regressió, però es podrien definir de nous seguint qualsevol criteri necessari:

- *Maximum*: utilitza totes les components d'aproximació disponibles a cada nivell per estimar les components de detall fent que el model de regressió ens permeti estimar de la manera més real possible les components de detall i per tant emmagatzemar valors molt pròxims a zero.
- *Restricted*: utilitza una sola component d'aproximació a cada nivell d'execució per calcular totes les components de detall d'aquests, això ho aconsegueix creant una equació de tercer grau, és a dir amb dos punts

d'inflexió. D'aquesta manera aconseguim una estimació no gaire rigorosa, però amb un cost computacional molt baix comparat amb la resta de models, tot mantenint al màxim possible l'escalabilitat de la DWT original.

- *Fast*: utilitza un subconjunt aleatori de  $m' = \rho * m$  elements, on  $m' \ll m$ , i  $m$  és el conjunt de components espacials de cada component d'aproximació per obtenir un submostreig espacial, per tant la precisió del model dependrà del tant per cent de detall tingut en compte per cada una de les component d'aproximació utilitzades. La selecció de  $\rho$  dependrà de criteris arbitraris per cada cas, aquest treball es centra en  $\rho = 0.01$  per ampliar els resultats del projecte previ, el que produeix una precisió espacial del 10%.
- *Exogenous*: utilitza les components d'aproximació d'una imatge (*training*) per calcular les components de detall de les  $n$  imatges següents (*test*). Aquest model veu condicionats els seus resultats segons la semblança de les imatges de test a la de *training*: quant més s'assembla més propers a zero seran les components de detall i per tant millors els resultats de la posterior compressió.




Fig. 3. Detall de l'algorisme RWA amb el filtre Haar sobre dos nivells de transformació. Els nivells de transformació aplicable estan definits per  $\log_2(z)$ , on  $z$  correspon al número de nivells espectrals. Els models de regressió poden ser definits segons sigui necessari.

## 4 OBJECTIUS

Promoguts per aquest anàlisi de l'estat de l'art i de les innovacions proposades es plantegen els següents objectius:

- Obtenir el *bitrate* amb una precisió de dues dècimes, en bits per píxel per component, de totes les imatges del conjunt de dades utilitzats en aquest projecte, amb els diferents models de regressió simples descrits al *paper* [6], per obtenir una base sobre la que comparar les noves dades de la resta d'objectius. L'esmentat conjunt es troba detallat a la següent secció 5 Conjunt de Dades i està format per setze imatges en la seva totalitat, provinent dels sensors AVIRIS i Hyperion
- Comparar els resultats anteriors per confirmar que s'obtenen resultats propers amb els presentats al *paper* sobre RWA [6].
- Desenvolupar els següents models de regressió combinats:

- *Restricted & Fast*
- *Restricted & Exogenous*
- *Fast & Exogenous*
- *Fast & Restricted & Exogenous*

- Obtenir el *bitrate* de tot el conjunt de dades que s'obté utilitzant els anteriors models compostos, amb la mateixa precisió del primer objectiu.
- Comparar els *bitrates* resultants amb els resultats que presenta el *paper* i veure si s'aconsegueix un rendiment de compressió pitjor, igual o superior a aquests.

## 5 ORGANITZACIÓ DEL DOCUMENT

A continuació, el document està organitzat començant amb una definició detallada del conjunt de dades utilitzat en aquest treball, incloent les dimensions espacials i espectrals de cadascuna de les imatges i el seu sensor d'origen. Seguidament, es troba la secció d'eines utilitzades, la qual es divideix en dos subseccions en la que es declaren tot el programari i els equips que s'han utilitzat per dur a terme els experiments detallats més endavant. Posteriorment, s'especifica la metodologia utilitzada per dur a terme el projecte de la manera més convenient possible. Una vegada plantejades aquestes seccions, s'exposa la planificació del treball que indica quins passos s'han efectuat per implementar-lo. Per continuar, es descriuen de manera detallada els canvis en la planificació realitzats al llarg d'aquest projecte i les solucions aplicades per part de l'alumne. I s'acaba amb els resultats obtinguts que estan dividits en dues seccions: l'explicació del sistema per trobar i validar els resultats obtinguts assegurant-nos així la seva correctesa abans de presentar-los i els resultats obtinguts en si mateixos amb la seva conseqüent discussió. I com a tancament, les conclusions obtingudes de l'aprenentatge extret al llarg del procés d'investigació que s'està presentant aquí, posant el punt i final amb la bibliografia utilitzada.

## 6 CONJUNT DE DADES

Les dades amb les que es treballa en aquest document estan formades per imatges cedides per la NASA i obtingudes mitjançant els sensors AVIRIS [7] instal·lat en un aeroplà destinat a aquestes tasques, i Hyperion [8] localitzat al satèl·lit espacial EO-1.

Les diferents imatges es troben en dos formats: calibrat (*Calibrated*) i no calibrat (*Uncalibrated*). El primer fa referència a dades que han estat corregides mitjançant diverses tècniques aplicables al camp de la teoria de la informació, mentre que el segon indica que són dades en la seva forma original captada pel sensor.

A cadascuna d'elles els hi corresponen diferents distribucions espacials i espectrals. Aquestes es detallen en la següent taula:

AVIRIS (Calibrated)			Imatge
z=224	y=512	x=677	Yellowstone 00
z=224	y=512	x=677	Yellowstone 03
z=224	y=512	x=677	Yellowstone 10
z=224	y=512	x=677	Yellowstone 11
z=224	y=512	x=677	Yellowstone 18
AVIRIS (Uncalibrated)			Imatge
z=224	y=512	x=680	Yellowstone 00
z=224	y=512	x=680	Yellowstone 03
z=224	y=512	x=680	Yellowstone 10
z=224	y=512	x=680	Yellowstone 11
z=224	y=512	x=680	Yellowstone 18
Hyperion (Calibrated)			Imatge
z=242	y=3129	x=256	Agriculture
z=242	y=3127	x=256	Coral Reef
z=242	y=2905	x=256	Urban
Hyperion (Uncalibrated)			Imatge
z=242	y=3187	x=256	ErtaAle
z=242	y=3176	x=256	Lake Monona
z=242	y=3242	x=256	Mt. St. Helens

Taula 1. Informació sobre les components espectrals i espacials de les imatges utilitzades en aquest document captades pels sensors AVIRIS i Hyperion. Z correspon al nombre de components espectrals, Y i X a l'altura i amplada respectivament de cada component espacial.

## 7 EINES UTILITZADES

### 7.1 Software

Aquest projecte pertany a l'àmbit de les tecnologies de la informació i les comunicacions en tant als sistemes de compressió desenvolupats i utilitzats, així com a la transmissió de les dades generades, però de la mateixa manera també pertany al marc matemàtic i computacional pels models matemàtics implicats en la resolució de la problemàtica presentada. Per aquests motius el desenvolupament del projecte referent a les transformades *Wavelet*, i els diferents models de regressió, s'ha efectuat completament fent ús del llenguatge i entorn de programació MATLAB [9].



Fig. 4. Logotip del llenguatge de programació orientat a matrius MATLAB (*Matrix Laboratory*).

Aquest llenguatge proveeix un gran conjunt d'eines de computació de grans prestacions, i permet desenvolupar codi molt eficient i optimitzat per millorar el seu rendiment a l'hora de ser executat. Es troba present en sistemes

de seguretat, naus espacials, dispositius de monitorització de la salut, xarxes elèctriques, sistemes de visió per computador, robòtica o processament d'imatges i senyals entre d'altres.

Per poder comprimir les imatges transformades, el software utilitzat ha estat KAKADU [10] en la seva versió per a Ubuntu, el que procura uns binaris que s'han configurat mitjançant BASH (*Bourne Again Shell*) [11], el llenguatge de programació d'scripts de Linux. Aquest permet automatitzar i executar ordres i tasques específiques, la qual cosa és totalment necessària per poder manipular i optimitzar els recursos dels sistemes operatius Linux.

### 7.2 Hardware

Els costos computacionals d'aquest projecte són considerablement elevats, i per consegüent es requereixen uns recursos mínims per poder dur a terme el desenvolupament. En concret el procés de transformació consumeix una gran quantitat de memòria RAM, i per contra la posterior fase de compressió de les dades obtingudes necessita d'una potència molt elevada de processament per part de la CPU. Les següents dades han estat obtingudes al monitoritzar el comportament dels equips durant els processos d'execució.

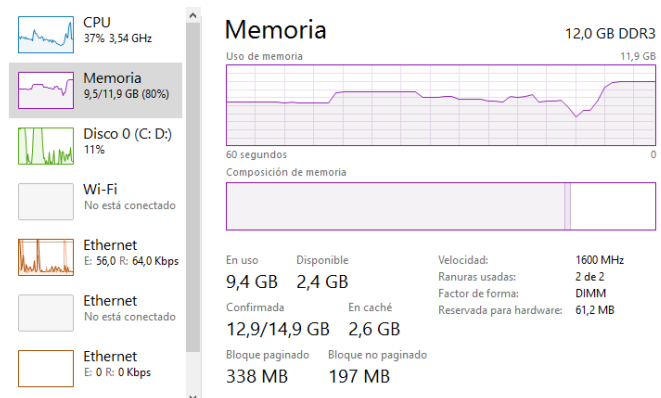


Fig. 5. Monitorització de dades durant l'execució de la RWA utilitzant el model *Maximum* amb la imatge ErtaAle. Es fa evident l'elevat consum de RAM sense una exagerada demanda de CPU.




Fig. 6. Monitorització de dades durant l'execució de la compressió amb Kakadu utilitzant el model *Exogenous* i les diferents imatges *Hyperion Uncalibrated*. Cada pic equival a una compressió. Es pot apreciar l'elevat consum de CPU sense gaire demanda de RAM.

Com aquest projecte conté una part comuna entre dos estudiants, inicialment es comptava amb dues màquines detallades a continuació:

Processador	i7 4790k	Processador	i7 4760
RAM	16Gb	RAM	12Gb
Targeta gràfica	GTX 970	Targeta gràfica	GTx 760
SO	WIN 10	SO	WIN 10

Taula 2. Informació sobre les característiques tècniques dels dos equips inicials utilitzats pel desenvolupament del sistema.

Però segons els canvis detallats a l'apartat 10 Canvis en la planificació, eventualment es va reparar una tercera màquina Linux amb les següents característiques:

Processador	i7 620M
RAM	8Gb
Targeta gràfica	ATI 5650 HD
SO	Ubuntu / Win 7

Taula 3. Informació sobre les característiques tècniques del tercer equip que es va reparar durant el desenvolupament del sistema per ampliar el throughput de treball.

## 8 METODOLOGIA DE DESENVOLUPAMENT

Al tractar-se d'un projecte enfocat a la investigació, la metodologia que es planteja per aquest tipus de projecte és la *Waterfall*.

Aquesta metodologia es basa en la consecució de diferents fases ben definides i en el requisit de completar cada una d'elles per poder passar a la posterior.



Fig. 7. Descripció gràfica de la metodologia *Waterfall* en la que per passar de fase a fase, les necessitats de l'anterior han d'haver estat satisfetes completament.

Aplicada a aquest projecte, la metodologia ens assegurarà que cada una de les fases explicades a la secció de planificació es validen i asseguren per poder corroborar que les dades que es comparen amb les fases prèvies són significatives.

## 9 PLANIFICACIÓ

Aquest projecte ha estat desenvolupat durant un període de quatre mesos, des de la primera reunió de planificació el 14 de febrer de 2016 fins a l'entrega dels documents finals, 26 de juny de 2016. El temps dedicat al desenvolupament no ha estat uniforme sinó exponencial, ja que pel transfons matemàtic que conté, les primeres etapes han estat més destinades a l'assimilació de la informació i els continguts del sistema, i una vegada el coneixement ha augmentat el suficient, s'ha passat a dedicar més hores a desenvolupar. Per tant la distribució de tasques ha quedat de la següent manera:

La primera fase del projecte es va destinar a l'estudi de la informació de la que es disposava, a través de la lectura

del *paper* en el que es basa aquest treball [6], a l'execució dels codis en MATLAB, desenvolupats i cedits pel departament i paral·lelament a assistir a reunions amb el tutor per assimilar els conceptes i plantejar i resoldre dubtes, que poguessin fer sorgir una via interessant de treball sobre la investigació del sistema de transformacions espectrals: *Regression Wavelet Analysis*. Les primeres proves esmentades es van fer executant les implementacions dels models de regressió simples: *Maximum*, *Restricted*, *Fast* i *Exogenous* utilitzant un parell d'imatges de mostra, també cedides pel departament, per executar proves a discreció.

Una vegada es va tenir suficient coneixement del sistema, es va decidir que el plantejament que tindria el projecte seria estudiar la combinació de models de regressió simples per tractar de trobar una millora en el rendiment de compressió o en el cost computacional.

Per poder comparar els resultats, la segona fase del projecte es va dedicar a executar un subconjunt d'experiments dels demostrats al treball previ en que es basa aquest projecte, i obtenir els mateixos *bitrates* d'aquests o similars. D'aquesta manera es construïa una base de valors lliandar sobre la que comparar els nous resultats que es volien obtenir.

El pas posterior va ser el desenvolupament dels codis en MATLAB responsables de l'execució de totes les combinacions de models de regressió i d'scripts *bash* per dur a terme les tasques de compressió i anàlisi de dades. Aquesta fase va ser orientada a la programació i el testeig del software necessari per dur a terme totes les proves per obtenir el resultats desitjats. Amb les noves eines a punt es van executar totes les transformacions sobre totes les imatges descrites a l'apartat 2 Conjunt de Dades. I es van validar tots els resultats com es descriu a l'apartat 7.1 Mètode de Validació del Resultats.




Fig. 8. Diagrama de Gantt especificant la distribució del temps al llarg del projecte.

Les etapes aquí descrites han anat acompanyades de reunions informals amb els membres del departament per demanar consells i comprovar i discutir els resultats que s'han anat obtenint fins a l'últim moment.

## 10 CANVIS EN LA PLANIFICACIÓ

Durant les primeres fases de disseny del projecte es va sospesar la inclusió de dades originaries d'un tercer sensor anomenat IASI (*Infrared Atmospheric Sounding Interferometer*) [12] propietat de la ESA (*European Space Agency*) [13], però finalment han estat retirades del conjunt fixat per als experiments, ja que les màquines que els duen a terme no han pogut suportar la càrrega necessària, i des del departament es va suggerir no incloure-les. D'altra banda, per obtenir dades d'un volum considerable d'imatges, en comptes de fer servir dues imatges de cada sensor com estava previst en un principi, finalment s'utilitzaran totes les disponibles en el cas d'Hyperion i totes les Yellowstone en el cas de las AVIRIS. Les dades finals són per tant, les indicades a la secció 2 Conjunt de Dades.

El procés de desenvolupament ha seguit la planificació definida en quant a l'execució del *Regression Wavelet Analysis* amb els diferents models de regressió fins al moment de la compressió, on es va decidir ampliar el Hardware utilitzat per incrementar el *throughput* de la càrrega de treball i optimitzar les posteriors fases:

### 10.1 Origen del Canvi

Els equips on s'han estat executant els entorns en tot moment per dur a terme les transformacions espectrals són màquines natives amb Sistema Operatiu Windows 10. Arribat el moment de la compressió de les dades, es va decidir executar aquest software específicament sobre un SO Linux per aprofitar el llenguatge BASH i crear així scripts que minimitzessin els possibles errors d'execució.

Amb els equips inicials però, no es va poder instal·lar aquest SO, ja que les màquines natives amb Windows 10 tenen grans problemes per poder executar sistemes *dual boot* a causa de la nova arquitectura UEFI (*Unified Extensible Firmware Interface*) [14], que fa que encara que el sistema operatiu s'hagi instal·lat correctament, no es pugui veure perquè inicialitza *Windows* sense passar per cap menü de selecció de sistema que estigui instal·lat, com per exemple GRUB (*GNU GRand Unified Bootloader*) [15] en aquest cas concret.

### 10.2 Canvi de Planificació Efectuat

Per solucionar la problemàtica, en un primer moment es van intentar reparar els sistemes *dual boot* a les dues màquines utilitzades, que eren les úniques amb potència necessària per poder dur a terme les tasques.

Però, ja que la motivació del canvi era augmentar la productivitat del projecte, per evitar endarreriments innecessaris, la solució definitiva ha estat reparar un tercer equip amb Windows 7 natiu, que disposava d'un procesador i7, però en el qual la memòria RAM es trobava avariada. Per fer-ho es van comprar i instal·lar dues SO-DIMM DDR3 1066 CL7 de 8Gb.

Finalment, aquesta incorporació juntament amb el desenvolupament de diferents scripts, han permès l'optimització dels recursos existents i la minimització d'errors.

## 11 RESULTATS

### 11.1 Mètode de Validació del Resultats

Cada imatge treballada en aquest projecte s'ha de transformar espectralment i comprimir, però una vegada comprimida serà necessària la descompressió de les dades i la inversió de la transformació per obtenir la imatge original sense pèrdua.

Per assegurar que els resultats obtinguts són els correctes, la fase de validació de les dades es divideix en dos etapes: primer es transformen les imatges i a continuació s'aplica la validació de primer nivell que consisteix en invertir la transformada i comprovar que el resultat obtingut és el mateix que l'original. Posteriorment, es prossegueix a comprimir la imatge transformada i assolit aquest punt s'aplica la comprovació de segon nivell, descomprimint la imatge, invertint la transformada, i comparant el resultat obtingut amb la imatge original. D'aquesta manera podem corroborar completament una de les premisses del projecte: que tot el procés de transformació i compressió ha estat sense pèrdua (*Lossless*).

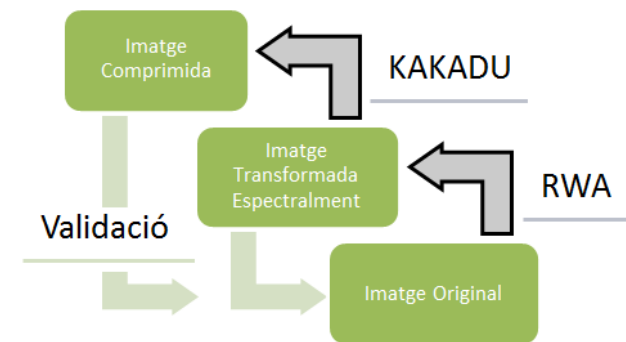


Fig. 9. Diagrama en detall que mostra gràficament la doble seqüència de: Transformació - Validació, Compressió - Validació.

### 11.2 Discussió dels Resultats

Les imatges, calibrades i no calibrades, captades pels sensors AVIRIS i Hyperion han estat transformades espectralment utilitzant els quatre models de regressió simple que es descriuen al paper *Regression Wavelet Analysis for Lossless Coding of Remote-Sensing Data*:

- *Maximum*
- *Fast*
- *Restricted*
- *Exogenous*

I amb la combinació del models desenvolupats durant aquest projecte:

- *Restricted & Fast*

- *Exogenous & Fast*
- *Exogenous & Restricted*
- *Exogenous & Restricted & Fast*

La hipòtesi inicial que es planteja indica que les execucions que utilitzin el model *Maximum* al ser el més precís, seran les que millor rendiment de compressió haurien de mostrar encara que també les que més costos computacionals han de tenir. D'altra banda, els models *Fast* haurien de veure empitjorats els seus resultats quan les magnituds espacials s'incrementin, els que utilitzin *Restricted* haurien d'oferir una solució amb un cert rendiment de compressió i un cost computacional baix, més o menys sever dependent d'amb quin altre model estigui combinat, i finalment, els models que utilitzin *Exogenous*, haurien de ser els que pitjors resultats mostressin donat que reutilitzen càlculs per a diferents imatges.

Començant pels resultats obtinguts a partir del subconjunt AVIRIS, les dades en relació als *bitrates*, referents a cada model de regressió, expressades en bits per píxel per component (bpppc), mostren en el cas de les imatges calibrades dos grups diferenciats: d'una banda, es pot observar que els models de regressió de l'anàlisi *Wavelet* formats de manera simple o composta per *Restricted* en tots els casos obtenen els menors rendiments. Això té sentit, tenint en compte que aquest model és el més permissiu a l'hora d'estimar les components de detall, fet que implica emmagatzemar més dades i per tant eliminar menys informació redundat. D'altra banda, la resta de models obtenen els millors resultats a l'hora de comprimir, inclòs *Exogenous*, el que significa que les cinc imatges han de ser bastant similars, ja que amb la utilització d'aquest model s'estan reutilitzant les dades obtingudes amb *Yellowstone00* per la resta d'imatges.

Aquest últim fet es veu reforçat si s'analitzen els patrons de rendiment d'una de les cinc imatges i es comparen amb la resta del subconjunt AVIRIS Calibrated. *Yellowstone00* no ofereix dades sobre els models *Exogenous* perquè és utilitzada com a base per estimar les components de detalls de *Yellowstone03*, *Yellowstone10*, *Yellowstone11* i *Yellowstone18*, però la resta d'imatges mostren una progressió del rendiment de compressió de millor a pitjor segons l'ordre: *Maximum* - *Fast* - *Exogenous* - *Exogenous & Fast* - *Restricted* - *Exogenous & Restricted & Fast* - *Restricted & Fast* excepte en el cas de la imatge *Yellowstone11*, en la que si ens fixem es pot observar que el model *Exogenous & Restricted* (4.09) és una centèsima millor en matèria de *bpppc* respecte a *Exogenous & Restricted & Fast* (4.10).

Per tant, o les imatges són molt similars entre si o els models són molt predictibles, però aquesta ultima possibilitat queda descartada en analitzar les dades obtingudes dels sensors *Hyperion* que es discuteixen més endavant.

En segon lloc, tenim les dades generades a partir de les

imatges captades pel sensor AVIRIS al format no calibrat. Aquestes, en referència als valors sobre els *bpppc* obtinguts, superen en uns 2 punts de mitja a les calibrades. Aquest fet s'explica basant-nos en que el format no calibrat no ha estat corregit d'imperficcions, que segons de quin tipus es tractin, poden arribar a fer més difícil la tasca de la compressió de les dades. Encara així, aquestes imatges segueixen el mateix patró dividit en dos grups diferenciats vist a les calibrades: un pels models que contenen *Restricted* i un altre pels que no estan composts per aquest, tenint una singularitat a la mateixa imatge que en el cas de les calibrades, és a dir, la imatge *Yellowstone11*, però en aquest cas és el model *Restricted* el que obté un pitjor rendiment que *Exogenous & Restricted & Fast*.

Aquests resultats es troben en gran mesura en conjunció amb el que es preveia des d'un inici, ja que al ser *Maximum* el model que més intenta semblar-se a les components de detall a partir de les components d'aproximació, s'espera que sigui el que produeixi un millor rendiment de compressió i és el que s'aprecia en tots els anteriors casos.

AVIRIS Calibrated

	Y00	Y03	Y10	Y11	Y18
Restricted & Fast	5,33	5,16	4,17	4,74	5,26
Exogenous & Restricted	-	4,33	3,67	4,09	4,60
Exogenous & Restricted & Fast	-	4,31	3,66	4,10	4,59
Restricted	4,44	4,31	3,66	4,06	4,50
Exogenous & Fast	-	3,64	3,27	3,54	3,74
Exogenous	-	3,63	3,25	3,52	3,72
Fast	3,75	3,59	3,19	3,48	3,66
Maximum	3,73	3,57	3,17	3,46	3,64

Taula. 4. *Bitrates* de les imatges *Yellowstone 00, 03, 10, 11 i 18* captades pel sensor AVIRIS Calibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge *Yellowstone 00* com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.




Fig. 10. *Bitrates* de les imatges *Yellowstone 00, 03, 10, 11 i 18* captades pel sensor AVIRIS Calibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge *Yellowstone 00* com a base per calcular els posterior resultats, fet que implica la no obtenció de dades sobre aquesta.

AVIRIS Uncalibrated

	Y00	Y03	Y10	Y11	Y18
Restricted & Fast	7,75	7,57	6,48	7,12	7,68
Exogenous & Restricted	-	6,53	5,83	6,31	6,85
Exogenous & Restricted & Fast	-	6,53	5,82	6,30	6,83
Restricted	6,68	6,51	5,82	6,44	6,76
Exogenous & Fast	-	5,97	5,56	5,83	6,08
Exogenous	-	5,95	5,55	5,81	6,05
Fast	6,08	5,91	5,48	5,78	5,98
Maximum	6,06	5,89	5,45	5,75	5,96

Taula 5. *Bitrates* de les imatges Yellowstone 00, 03, 10, 11 i 18 captades pel sensor AVIRIS Uncalibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge Yellowstone 00 com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.




Fig. 11. *Bitrates* de les imatges Yellowstone 00, 03, 10, 11 i 18 captades pel sensor AVIRIS Uncalibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge Yellowstone 00 com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.

El tercer subconjunt és el que pertany a les dades generades a partir de les imatges, en la versió calibrada, captades pel sensor Hyperion. Sense tenir en compte les dades de *Restricted & Fast*, sobre les que es discutiran al final de la secció, es pot apreciar que en aquest cas totes les execucions oscil·len en uns rangs molt similars, sent concretament els mínims i els màxims de cada imatge: Agriculture (5.47 - 5.55), CoralReef (5.11 - 5.25), Urban (5.44 - 5.63). A més, a diferència de les dades d'AVIRIS, els models de regressió *Exogenous & Fast* i *Fast*, de manera molt subtil, mostren un *bitrate* pitjor als dels que estan formats per *Restricted*.

Aquests resultats semblen estar condicionats per dos factors: en primer lloc, les imatges són menys similars entre si que les AVIRIS, fet que provoca un pitjor rendiment de compressió en utilitzar models *Exogenous*, ja que les components d'aproximació utilitzades per estimar les components de detall de la resta d'imatges no són gaire eficients. En segon lloc, al tractar amb imatges formades per un nombre molt més elevat de components espacials (al voltant de 256 x 3100 píxels, en funció de cada imatge), les transformacions espectrals més lleugeres com les que

executa *Restricted* adquireixen un cert interès. Tot i sent aquests els resultats, *Maximum* continua oferint els millors resultats en quant a rendiment de compressió, excepte, de manera lleugera, en el cas d'*Urban*, on *Fast* obté un valor de 5.44 bpppc i *Maximum* un 5.48 bpppc.

Com a quart i últim subconjunt de dades a analitzar tenim les imatges sense calibrar que han estat captades pel sensor Hyperion. Aquestes dades ens proporcionen el conjunt de dades més dispar i menys similar als resultats esperats dels analitzats.

En un primer anàlisi es pot observar la inversió del patró de separació en dos grups vist a les dades provinents del sensor AVIRIS, en aquest cas els models formats per *Restricted* obtenen un millor rendiment de compressió que els que no estan formats per aquest. Inclòs *Restricted & Fast*, model sobre el que es discutirà al final de l'apartat de resultats.

Aquest canvi de paradigma mostrat als resultats sembla estar condicionat pel format de les imatges. Al tractar-se de versions no calibrades de les imatges, aquestes tenen moltes més imperfeccions, ja que no se'ls hi ha aplicat cap tipus de correcció ni filtratge, i en aquest cas si es realitza un anàlisi visual del subconjunt, es pot observar que es reproduïxen uns patrons molt característics en forma de línies de soroll. Aquestes línies de soroll, que es propaguen per la continuïtat dels canals d'una mateixa imatge, constitueixen un clúster de dades molt properes entre si, perfectes per ser estimades per una funció de regressió de tercer grau, com és el cas del model *Restricted* i tots els que estan compostos per ell.

Encara que no essent tan notoris com els anteriors resultats, seguint amb el mateix grup d'imatges, es poden apreciar dos factors a subratllar. D'una banda, que els models *Exogenous* obtenen els rendiments de compressió menys significatius, dintre dels dos subgrups de: formats i no formats per *Restricted*. Fet que indica la falta de semblança entre les diferents imatges. I de l'altra, que les composicions de *Fast* ofereixen resultats pitjors que *Maximum*.

Hyperion Calibrated

	Agriculture	CoralReef	Urban
Restricted & Fast	6,07	5,50	6,19
Exogenous & Restricted	-	5,19	5,63
Exogenous & Restricted & Fast	-	5,17	5,57
Restricted	5,55	5,19	5,58
Exogenous & Fast	-	5,25	5,57
Exogenous	-	5,25	5,56
Fast	5,47	5,11	5,44
Maximum	5,47	5,11	5,48

Taula 6. *Bitrates* de les imatges Agriculture, CoralReef i Urban captades pel sensor Hyperion Calibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge Agriculture com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.





Fig. 12. *Bitrates* de les imatges Agriculture, CoralReef i Urban captades pel sensor Hyperion Calibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge ErtaAle com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.

	ErtaAle	LakeMonona	MtStHelens
Restricted & Fast	4,73	4,94	4,92
Exogenous & Restricted	-	4,48	4,39
Exogenous & Restricted & Fast	-	4,52	4,41
Restricted	4,26	4,46	4,40
Exogenous & Fast	-	5,24	5,20
Exogenous	-	5,22	5,17
Fast	4,71	4,91	4,76
Maximum	4,70	4,90	4,75

Taula. 7. *Bitrates* de les imatges ErtaAle, LakeMonona i MtStHelens captades pel sensor Hyperion Uncalibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge ErtaAle com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.




Fig. 13. *Bitrates* de les imatges ErtaAle, LakeMonona i MtStHelens captades pel sensor Hyperion Uncalibrated, referents a cada model de regressió expressades en bits per píxel per component (bpppc). Els models *Exogenous* utilitzen la imatge ErtaAle com a base per calcular els posterior resultats, fet que implica la no obtenció de dades d'aquesta.

Aquest resultats han estat validats seguint la metodologia descrita anteriorment i després d'analitzar les dades en profunditat, s'ha detectat un error pel que no s'ha trobat correcció, pel que ha quedat fora de la discussió presentada. És el cas del model *Restricted & Fast*.

Des del departament s'han discutit les dades i s'ha vist que partint de la premissa que *Exogenous* reutilitza com-

ponents d'aproximació, aquest model només pot oferir resultats iguals o pitjors, en quant a compressió es refereix, que el model amb el qual estigui combinat per cada imatge. Per tant, si *Exogenous & Restricted & Fast* ofereix un millor rendiment de compressió que *Restricted & Fast*, un d'aquests models de regressió ha de tenir alguna inconsistència en la seva execució.

Així que com s'ha dit, seguint amb la metodologia d'anàlisi i verificació de resultats, s'ha detectat que existeix alguna mena d'error, que no s'ha pogut localitzar, en l'execució dels models *Restricted & Fast*, ja que tant de manera lògica com amb proves fallides per invertir les transformades *Wavelet*, els resultats han estat negatius.

No obstant això, sembla ser, que el model *Exogenous & Restricted & Fast*, com tota la resta, si que són validats, el que apunta a la causa de l'anterior problema com a un error humà d'execució, ja que aquest model està format per *Restricted & Fast*, tot i així, s'ha revisat el treball des de el departament i no s'ha pogut trobar cap mena d'explicació ni error de codi, càlcul o execució que pogués indicar la causa d'aquest fet.

Com a punt de tancament de la discussió i per denotar els valors dels diferents models, amb independència de que obtinguin o no el millor rendiment de compressió, ha de ser esmentat que, encara que no existeixen grans diferències entre els rendiments dels últims quatre models de regressió, si comparem aquests amb el costos computacionals dels models simples que es mostren a la figura 14 [5], es pot observar que la relació entre els dos grups de dades, indica que, existeix una relació molt interessant i explotable en funció de les necessitats intrínseques de cada tipus d'imatge o conjunt d'imatges per al que es vulgui utilitzar *Regression Wavelet Analysis*. I per extensió a les combinacions de models de regressió que els integren.




Fig. 14. Comparació del cost en FLOP entre diferents transformades per una imatge no calibrada del sensor AVIRIS de 224 components espectrals i una resolució espacial de 512 x 680 [6].

## 12 CONCLUSIONS

Revisant els objectius es pot concloure que s'han complert tots ells, encara que a l'analitzar en profunditat els resultats s'ha detectat un error que no s'ha pogut corregir a les dades obtingudes del model *Restricted & Fast*. Aquest fet ha propiciat que les comparatives de la discussió no el tinguessin en compte.

Els *bitrates* resultants han estat comparats amb els resultats que presenta el *paper* i en general els rendiments de compressió combinats obtinguts han estat pitjors a aquests, i per tant no suposen una millora en aquest aspecte. No obstant, comparant amb la taula de costos computacionals es presenten algunes conclusions interessants.

*Maximum* simple ofereix els millors resultats en la majoria dels casos.

Els models com *Fast* demostren grans aplicacions, ja que s'executen en un temps menor que regressions *Maximum*, obtenint un rendiment de compressió bastant similar a aquestes, amb un cost computacional menys elevat.

Els models com *Restricted* poden oferir solucions molt eficients amb dades hiperespectrals semblants entre si, que es distribueixin de manera pròxima a una funció de regressió de tercer grau, mostrant un cost computacional molt reduït.

Els models que utilitzin *Exogenous* aprofiten l'explotació d'un sol anàlisi per diferents imatges, fet que implica que, quantes més imatges el facin servir, menor cost computacional es requerirà de manera global, i per tant, l'estudi de similituds entre imatges prèvies a les transformacions pot induir a una major eficiència utilitzant aquestes regressions.

Les dades no calibrades sobre Hyperion mostren uns resultats totalment diferents a la resta, on els models *Restricted* són els més favorables. Aquest fet sembla ser produït perquè el format no calibrat comporta errors sense filtrar, que en aquest cas concret són línies repetides al llarg de tots els canals, les quals poden ser fàcilment estimades per la funció de tercer grau que implementa *Restricted*.

Futures aplicacions d'aquest estudi podrien focalitzar-se en la relació dels *bitrates* de les compressions i els costos computacionals de cadascun d'aquests per indicar si es segueixen tendències lineals, exponencials, logarítmiques o d'altres.

Aprofitant aquestes dades es podria descriure un model matemàtic que analitzés el temps de transformació i el temps de compressió, juntament amb el de transmissió de les dades i aplicar una funció d'optimització derivant el model i buscant el mínim dels punts d'inflexió de la funció resultant, obtenint així la combinació d'execucions

més òptima per cada cas en funció dels recursos que es disposen. Per exemple, un satèl·lit situat a l'espai que té un hardware no actualitzable al llarg del temps, podria preferir prioritzar el temps de transmissió respecte al de transformació, i pel contrari un laboratori d'una universitat amb grans clústers dedicats a la computació podrien voler donar preferència a la transformació versus a la transmissió.

## BIBLIOGRAFIA

- [1] "Lossless Data Compression", Cs.stanford.edu, 2016. [Online]. Disponible: <https://cs.stanford.edu/people/eroberts/courses/soco/projects/2000-01/data-compression/lossless/index.htm>. [Consultat: 1- Jun- 2016].
- [2] "Lossy Data Compression", Cs.stanford.edu, 2016. [Online]. Disponible: <https://cs.stanford.edu/people/eroberts/courses/soco/projects/2000-01/data-compression/lossy/index.htm>. [Consultat: 1- Jun- 2016].
- [3] "Principal Component Analysis explained visually", *Explained Visually*, 2016. [Online]. Disponible: <http://setosa.io/ev/principal-component-analysis/>. [Consultat: 14- Jun- 2016].
- [4] *Johnsonhsieh.github.io*, 2016. [Online]. Disponible: [http://johnsonhsieh.github.io/DSR\\_workshop/image/fig\\_pca\\_principal\\_component\\_analysis.png](http://johnsonhsieh.github.io/DSR_workshop/image/fig_pca_principal_component_analysis.png). [Consultat: 14- Jun- 2016].
- [5] G. Chenchu Krishnaiah, T. Jayachandraprasad and M. Giri Prasad, "Efficient Image Compression Algorithms Using Evolved Wavelets", *International Journal of Systems and Technologies*, 2016.
- [6] N. Amrani, J. Serra-Sagrista, V. Laparra, M. Marcellin, J. Malo, *Regression Wavelet Analysis for Lossless Coding of Remote-Sensing Data IEEE Transactions on geoscience and remote sensing*, Vol. 54, in press, 2016.
- [7] "AVIRIS - Airborne Visible / Infrared Imaging Spectrometer - General Overview", *Aviris.jpl.nasa.gov*, 2016. [Online]. Disponible: <http://aviris.jpl.nasa.gov/aviris/index.html>. [Consultat: 15- May- 2016].
- [8] "USGS EO-1 Website - <http://eo1.usgs.gov>", *Eo1.usgs.gov*, 2016. [Online]. Disponible: <https://eo1.usgs.gov/sensors/hyperion>. [Consultat: 08- Jun- 2016].
- [9] "MATLAB - MathWorks", *Mathworks.com*, 2016. [Online]. Disponible: <http://mathworks.com/products/matlab/>. [Consultat: 02- Jun- 2016].
- [10] "Kakadu Software", *Kakadusoftware.com*, 2016. [Online]. Disponible: <http://kakadusoftware.com/software/>. [Consultat: 18- Jun- 2016].
- [11] "bash", *Linuxcommand.org*, 2016. [Online]. Disponible: [http://linuxcommand.org/man\\_pages/bash1.html](http://linuxcommand.org/man_pages/bash1.html). [Consultat: 05- Jun- 2016].
- [12] T. Erbertseder, "IASI Sensor WDC-RSAT", *Wdc.dlr.de*, 2016. [Online]. Disponible: <http://wdc.dlr.de/sensors/iasi/>. [Consultat: 07- Jun- 2016].
- [13] "ESA", *European Space Agency*, 2016. [Online]. Disponible: <http://www.esa.int/ESA>. [Consultat: 07- Jun- 2016].
- [14] "About UEFI Forum | Unified Extensible Firmware Interface Forum", *Uefi.org*, 2016. [Online]. Disponible: <http://www.uefi.org/about>. [Consultat: 03- May- 2016].
- [15] B. Dubbs, "GNU GRUB - GNU Project - Free Software Foundation (FSF)", *Gnu.org*, 2016. [Online]. Disponible: <https://www.gnu.org/software/grub/>. [Consultat: 03- May- 2016].