



UNIVERSITAT POLITÈCNICA
DE CATALUNYA
BARCELONATECH



Compressió Geomètrica de Núvols de Punts amb MPEG G-PCC

**Escola Tècnica d'Enginyeria de Telecomunicació de Barcelona
Universitat Politècnica de Catalunya**

Roger Reguan Font

**Treball Final de Grau
ENGINYERIA DE TECNOLOGIES I SERVEIS DE
TELECOMUNICACIÓ**

Supervisor: Josep R. Casas Pla

Barcelona, Juny 2021

Abstract

MPEG G-PCC (Geometric Point Cloud Compression) uses technologies like octrees, rasterization and arithmetic coding for compression for non-projectable 3D point clouds. A reference implementation is available as G-PCC Test Model v11. The aim of this project is to explore the performance of G-PCC.

Finding different coding tools that propose various ways to perform this geometric compression is part of the challenge. Obtaining datasets and being able to test the efficiency of these software is key to understand the idea behind all these techniques, which are part of a research field in which the breakthroughs are still to come.

Resum

MPEG G-PPC (Geometric Point Cloud Compression) utilitza tecnologies com octrees, rasterització i codificació aritmètica per a la compressió de núvols de punts 3D no projectables. Una implementació de referència està disponible com a model de test de MPEG. L'objectiu d'aquest projecte és explorar les tècniques de G-PCC.

Fer recerca de diferents codificadors que proposin diverses maneres de realitzar aquesta compressió geomètrica forma part del repte. Obtenir datasets i poder fer proves de l'eficàcia d'aquests software és clau per comprendre la idea que hi ha darrere de totes aquestes tècniques, que formen part d'un àmbit d'investigació en el qual els grans avenços encara han de venir.

Resumen

MPEG G-PCC (Geometric Point Cloud Compression) utiliza tecnologías como octrees, rasterización i codificación aritmética para la compresión de nubes de puntos 3D no proyectables. Una implementación de referencia está disponible como modelo de test de MPEG. El objetivo de éste proyecto es explorar las técnicas de G-PCC.

Encontrar diferentes codificadores que propongan varias maneras de realizar esta compresión geométrica forma parte del reto. Obtener datasets i poder realizar pruebas de la eficacia de estos softwares es clave para comprender la idea que hay detrás de todas estas técnicas, que forman parte de un ámbito de investigación en el cual los grandes avances están aún por venir.

Agraïments

M'agradaria agrair al meu tutor Dr. Josep R. Casas per la seva ajuda, suport i guia. També voldria donar les gràcies a la meva família i amics de tota la vida pel suport sempre present davant les dificultats. Finalment, les més sinceres gràcies a tots els meus amics enginyers i enginyeres, que han fet la meva experiència a la universitat encara més enriquidora.

Historial de revisió i aprovació

Revisió	Data	Motiu
0	30/04/2021	Creació del document
1	25/05/2021	Revisió del document
2	03/06/2021	Revisió del document
3	15/06/2021	Revisió del document
4	21/06/2021	Entrega del document

LLISTA DE PARTICIPANTS

Nom	e-mail
Roger Reguan Font	roger.reguan@estudiantat.upc.edu
Josep Ramon Casas Pla	josep.ramon.casas@upc.edu

Escrit per:		Revisat i validat per:	
Data	30/04/2021	Data	21/06/2021
Nom	Roger Reguan	Nom	Josep R. Casas
Posició	Autor del projecte	Posició	Supervisor del projecte

Taula de continguts

Abstract.....	1
Resum	2
Resumen	3
Agraïments	4
Historial de revisió i aprovació	5
Taula de continguts	6
Llista de figures	8
1. Introducció.....	9
1.1. Objectius	9
2. State of the art en compressió de núvols de punts (Point Cloud Compression)	10
2.1. Video-based Point Cloud Compression	12
2.2. Geometry-based Point Cloud Compression	13
2.2.1. Codificació de la geometria.....	13
2.2.1.1. Codificació Octrees	14
2.2.1.2. Codificació Trisoup.....	15
2.2.2. Codificació de l'atribut	16
2.2.2.1. Predicting i Lifting Transforms	16
2.2.2.2. Region Adaptative Hierarchical Transform.....	17
3. Metodologia en l'exploració i avaluació de codificadors	18
3.1 Codificadors.....	18
3.1.1. TMC 13, MPEG	18
3.1.2. Draco, Google	19
3.2 Datasets.....	20
3.2.1 8iVSLF	20
3.2.2 LS3DPC	21
3.3 Avaluació dels resultats.....	22
4. Resultats	25
4.1. Compressió amb TMC13.....	25
4.2. Compressió amb Draco.....	29
5. Costos	35
6. Conclusions.....	36
Bibliografia:.....	38
Annexes.....	40



Glossari..... 43

Llista de figures

Figura 1: Núvol de punts organitzat	11
Figura 2: Núvol de punts no organitzat	11
Figura 3 Compressió V-PCC.....	12
Figura 4: Exemple de procés de voxelització.	14
Figura 5: Exemple de procés de voxelització en termes de l'atribut.....	14
Figura 6: Exemple de codificació Octree	15
Figura 7: Exemple de descodificació Trisoup.....	16
Figura 8: Exemple de Predicting Transform	16
Figura 9: Exemple de codificació RAHT	17
Figura 10: Presentació per pantalla de les opcions de Draco.....	19
Figura 11: Previsualització de núvols del dataset LS3DPC	21
Figura 12: Distància de punt a pla.	23
Figura 13: PSNR amb la codificació Octree	25
Figura 14: Visualització de resultats. TMC13 Octree	26
Figura 15: PSNR amb la codificació Trisoup.....	26
Figura 16: Visualització de resultats. TMC13 Trisoup.....	27
Figura 17: PSNR en funció de la mida del fitxer comprimit. Octree vs Trisoup.....	27
Figura 18: Visualització de resultats amb codificació sense pèrdues.....	28
Figura 19: Resultats de la codificació d'atribut. Predlift vs RAHT	28
Figura 20: PSNR en funció del bitstream de posició, compressió amb Draco.	29
Figura 21: Resultats visuals amb diferents mides del bitsteam de posició.....	30
Figura 22: Mida del fitxer en funció del nivell de compressió.....	30
Figura 23: Mida del fitxer en funció de la quantificació de la posició	31
Figura 24: Temps de codificació en funció del nivell de compressió	31
Figura 25: Temps de codificació en funció del nivell de quantificació de posició.....	32
Figura 26: Núvol de punts original, two_building.ply.	33
Figura 27: two_building.ply amb 6 bits per al valor d'atribut.	34

1. Introducció

Aquest projecte es porta a terme al Departament de Teoria del Senyal i de Comunicacions de la UPC, en el Grup de Processament d'Imatge (GPI), supervisat pel professor Josep R. Casas.

Una escena 3D capturada per un sensor de distància es representa amb un núvol de punts. Aquest punts poden contenir informació tant de la geometria com de la textura de color dels objectes presents. Cada punt, per tant, inclou les seves coordenades espacials (x,y,z) i un possible valor que dóna informació sobre l'atribut (intensitat, color RGB...). Un núvol de punts també pot contenir les normals a les superfícies per cada punt, o els vèrtexs, les cares i les textures d'una malla formada per aquests punts. Això es tradueix en un elevat volum d'informació i, en la majoria dels casos, aquesta no està gaire correlada: cada punt del núvol no té un veïnatge definit, com sí succeeix amb els píxels d'una imatge 2D. Amb tot, la compressió eficient de núvols de punts és encara, a dia d'avui, un gran repte per a la investigació en el camp de les tecnologies 3D.

MPEG treballa actualment en la codificació geomètrica de núvols de punts, en anglès Geometric Point Cloud Coding (G-PCC) [1], [2]. La implementació disponible [3] requereix un temps per a la codificació i descodificació que suposa un coll d'ampolla per sistemes orientats a tenir el menor *retard* possible, com per exemple en Telepresència 3D, on la compressió dels *frames* (núvols de punts per cada instant de temps) ha de ser en temps real. El propòsit d'aquest projecte és prendre la implementació de referència d'MPEG i avaluar el seu comportament en comparació amb altres solucions proposades.

1.1. Objectius

Els principals objectius d'aquest projecte són:

1. – Estudi i aprenentatge sobre la compressió G-PCC i la seva implementació.
2. – Recerca de diferents codificadors G-PCC.
3. - Avaluar ràtios de compressió, latències i pèrdues. (en el cas de codificació amb pèrdues.).

Aquest projecte parteix de zero al sí del GPI i vol ser una important contribució al sistema de Telepresència 3D bidireccional amb Realitat Virtual que el grup està desenvolupant actualment.

2. State of the art en compressió de núvols de punts (Point Cloud Compression, PCC)

Actualment, amb les noves tècniques d'adquisició d'escenes 3D, ha aparegut un nou tipus de dades: Els núvols de punts, Point Clouds en anglès. Aquests, no segueixen l'estructura habitual d'una imatge 2D, on tots ells es troben emmagatzemats en una matriu d' $N \times N$ identificats pel seu atribut com sol ser color (no necessiten informació de posició, que ve donada per l'ordre d'exploració i el número de píxels en una amplada d'imatge). En aquest cas se situen de manera dispersa en l'espai tridimensional i cada punt ha de contenir les seves coordenades x, y, z i informació sobre el color o qualsevol altre atribut.

Això fa que no es puguin aplicar tècniques de compressió habituals en imatge. En aquest context, MPEG ha proposat dues principals maneres d'atacar aquest problema.

Quan parlem de compressió de núvols de punts, podem distingir entre dos tipus de dades diferents. Per una banda, tenim els núvols de punts organitzats (o projectables), que permeten ser projectats en plans bidimensionals. Per l'altra, trobem núvols de punts no organitzats, que requereixen d'un tractament diferent, ja que no permeten obtenir superfícies fiables ni projeccions matricials sobre el pla 2D. Degut a això, MPEG treballa en dos còdecs per PCC[1]. En aquesta tesi tractarem el segon cas.

Vegem amb més profunditat les característiques d'aquesta classificació:

▪ Núvol de punts organitzat

Similar a l'estructura d'una imatge organitzada, com una matriu, amb la informació ordenada per files i columnes. Aquestes dades provenen de sensors estereoscòpics, de profunditat o de llum infraroja. Destaquen com a característiques principals:

- núvol de punts **projectable**: existeix una correlació segons el model de càmera estenopeica entre l'índex (u, v) d'un punt del núvol organitzat i els valors reals en 3D (x, y, z) . Aquesta correlació pot expressar-se com: $u = f_x \cdot x/z$ y $v = f_y \cdot y/z$, on f_x i f_y són les distàncies focals de la càmera
- Coneixent la relació entre punts adjacents (com en el cas dels píxels), operacions amb el veïnatge són molt més eficients, augmentant així la velocitat de còmput i abaratint costos de determinats algorismes en PCL.

Degut a la seva adquisició, la captura realitzada es veu completament només des de l'angle en què s'ha capturat. Quan naveguem a través del núvol o en canviem l'angle de visualització apareixen les anomenades ombres. Queda palès a la Figura 1, on a

l'esquerra se situa el núvol de punts adquirit des de la mateixa posició que enfoca la imatge de la dreta.



Figura 1: Núvol de punts organitzat

La part de taula que queda tapada pel bol vermell o darrera dels braços de la persona no pot ser adquirida pels sensors (queda a l'ombra) i observem que el núvol no en té informació.

- **Núvol de punts no organitzat**

Mostrejat no regular de l'espai 3D, normalment a partir de diversos sensors 3D o un sensor 3D en moviment per a escanejar una escena. En aquest tipus de núvols les operacions basades en el veïnatge requereixen eines eficients com el KD-Tree per trobar els veïns més propers d'un punt qualsevol del núvol. En aquest cas, sovint ens podem moure al voltant del núvol amb un software de visualització adient.



Figura 2: Núvol de punts no organitzat [4]

Un LIDAR és un tipus de sensor de profunditat adequat per distàncies més grans en exteriors. Quan s'empra un LIDAR per a l'adquisició del núvol de punts, sovint no es capten tots els punts dels elements més llunyans i aquests són dispersos en l'espai i sense una repartició homogènia. Un frame de LIDAR genera un núvol de punts organitzat, però l'acumulació de diversos frames de LIDAR en un sol núvol de punts, com és sol fer per explorar trajectòries possibles en aplicacions en conducció autònoma, genera un núvol de punts no organitzat.

Igualment, els múltiples sensors 3D de la sala on es treballa amb el projecte de telepresència, registren els seus núvols de punts per cada frame en un núvol de punt no organitzat, que és el que s'ha de transmetre en temps real a les ulleres de realitat virtual del receptor per tal que vegi l'interlocutor en tres dimensions des de qualsevol orientació.

2.1. Video-based Point Cloud Compression

La compressió de vídeo en 2D és molt recurrent en l'actualitat i compta amb un ampli ventall d'estàndards de codificació. És per això que una estratègia per a la compressió de núvols de punts és la basada en vídeo (V-PCC), que projecta la informació del núvol de punts 3D sobre *patches* de vídeo 2D per poder tractar la informació amb codificadors de vídeo 2D estàndard.

Per la compressió de cada patch, obtenim tres imatges amb informacions ben diferents:




Figura 3 Compressió V-PCC dl núvol de punts de l'esquerra emprant (1) un mapa d'ocupació, (2) una imatge geomètrica de profunditat, i (3) una imatge amb la informació de color [5]

(1) Una imatge binària, anomenada *mapa d'ocupació*, que indica per cada píxel si correspon o no a un punt projectat vàlid de l'escena. (2) Una imatge geomètrica, que conté

la informació de profunditat (p. ex. la distància entre la posició de cada punt i el pla de projecció). (3) Una imatge de valors per a cada atribut.

2.2. Geometry-based Point Cloud Compression

L'estàndard basat en la geometria G-PCC, desenvolupat per JPEG, ha adoptat una aproximació de la codificació basada en *octree* combinat amb una representació de la superfície basada en triangles. Això defineix el comportament del descodificador, però no fixa el comportament del codificador. MPEG dóna llibertat al mercat per a crear competència entre les diferents organitzacions, que investiguen nous mecanismes per explotar al màxim les propietats del senyal i obtenir millors resultats de compressió [3].

Les investigacions més recents intenten aplicar tècniques d'aprenentatge automàtic amb algorismes de compressió per adaptar-se a les característiques de cada bloc, com es presenta a [6].

A continuació s'aprofundeix en l'estàndard basat en geometria proposat per MPEG, d'interès per a núvols de punts no organitzats. Distingeix en primer lloc la geometria de l'atribut o color, i codifica cadascuna d'aquestes informacions de manera separada. Tot seguit es presenten les diferents tècniques per a la codificació d'aquests camps.

2.2.1. Codificació de la geometria

Per tal de comprendre les diferents tècniques de codificació de la geometria en la G-PCC cal introduir, prèviament, el concepte de voxelització:

Voxelització: És el procés de quantificació de l'espai de dades. El núvol de punts es divideix en vòxels (coneguts també com elements de volum –volume element– o píxels volumètrics), que és la unitat més petita que descriu una frame 3D. A tots els punts continguts dins d'un mateix vòxel se'ls associa les coordenades del punt central i, típicament com a valor d'atribut, la mitjana, ponderada en funció de la distància al centre, de tots els punts continguts al propi vòxel [2].




Figura 4: Exemple de procés de voxelització.

Així doncs, per exemple, els punts de la figura 1, resultaran en 4 punts, cadascun centrat a un vòxel i amb valor d'atribut el color (RGB, YCbCr...) del vòxel que els contingui.




Figura 5: Exemple de procés de voxelització en termes de l'atribut [7].

A la pràctica, quan treballem amb núvols de punts, degut a la naturalesa del senyal, al voltant de l'1% dels vòxels contenen dades. La resta de vòxels solen quedar buits. És per això que existeixen diferents tècniques que aprofiten aquesta característica per representar les dades de manera eficient:

2.2.1.1. Codificació Octrees

Aquesta és una tècnica de codificació sense pèrdues que aprofita els grans volums amb absència de punts. Es divideix inicialment el volum cúbic de costat D que conté el núvol en vuit blocs de costats $D/2$. Aquest procés es realitza de manera reiterada en cada sub-bloc que contingui núvols de punts, detectant ràpidament aquelles zones on no hi ha informació, fins que el costat del sub-bloc sigui igual a la unitat.

Assignant a cada sub-bloc un 1 o un 0 per iteració, en funció de si estan o no ocupats, aconseguim paraules de 8 bits (1byte) cadascuna de les quals pertany a sub-bloc que conté punts. Aquestes es comprimeixen amb un codificador entròpic tenint en compte el seu veïnatge.

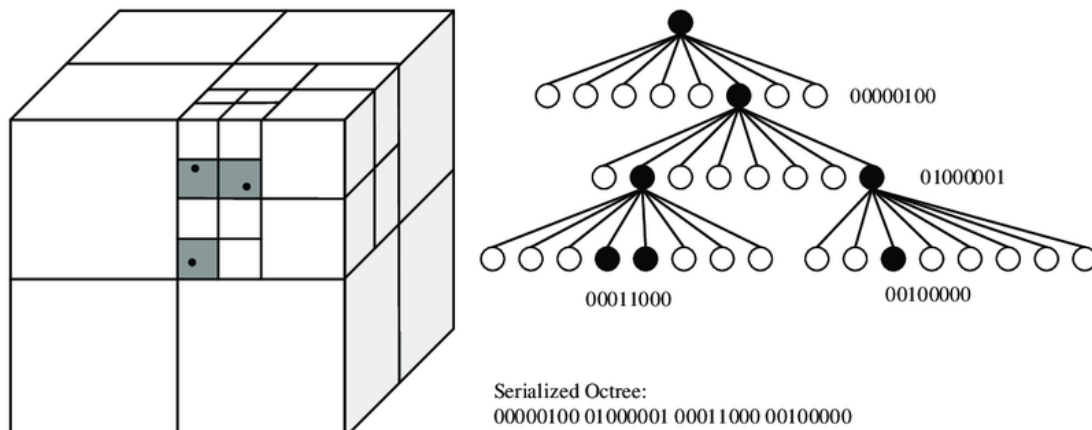


Figura 6: Exemple de codificació Octree

Els punts aïllats es codifiquen sense comprimir, ja que no existeix una correlació explotable amb altres punts. Aquest mode s'anomena Direct Codification Mode, DCM [5].

El nom d'aquesta tècnica prové de la seva estructura en forma d'arbre on el nivell inicial és l'arrel, i els últims nivells s'anomenen fulles.

2.2.1.2. Codificació Trisoup [8]

Una alternativa a la tècnica anterior, és l'aproximació de la superfície basada en triangles. Trisoup, que en anglès ve del sintagma nominal "sopa de triangles". Es basa en l'estructura d'arbre esmentada anteriorment, però en aquest cas, l'arbre està tallat en nivells previs a arribar a les fulles. Provoca, per tant, una major quantificació dels punts que es tradueix en un menor bitrate. Després es creen triangles a partir d'aquests punts com a vèrtexs i es busca l'aproximació de la superfície.




Figura 7: Exemple de descodificació Trisoup [5]

El descodificador cerca les interseccions entre la superfície definida pels triangles i els vèrtexs de cada vòxel per poder recuperar les coordenades i atributs del núvol de punts.

2.2.2. Codificació de l'atribut

2.2.2.1. Predicting i Lifting Transforms [5]

La tècnica de Predicting Transform es basa en la idea de definir diferents capes de qualitat per al color o atribut. Dins de la mateixa capa i/o entre capes es realitza predicció dels atributs d'alguns punts a través del seu veïnatge.

Per tal de fer això, necessitem que els punts estiguin ordenats (no confondre amb núvol organitzat) d'una manera concreta. Es realitza la ordenació de tal manera que la primera capa, amb un número reduït de punts, ja defineixi la distribució del color o atribut. Seria el cas dels punts vermells de la Figura 8:




Figura 8: Exemple de Predicting Transform

Suposant que es treballa només amb la primera cap LoD0, l'atribut del punt 2 pot ser predit pel punt P0, P5 i P4, realitzant una ponderació dels seus atributs en funció de la distància a la que es troben del punt a predir, el 2. El codificador determina el número màxim de punts a predir per capa i també determina el número màxim de veïns k que realitzen la

predicció. Els punts de la capa n es prediuen a partir del veïnatge d'aquell punt a la capa $n-1$.

La tècnica de Lifting Transform es tracta d'una versió de la Predicting transform millorada. Com que les capes de menor nivell són molt més utilitzades, tenen més impacte en el procés de codificació i, per tant, es realitza una quantificació no uniforme al llarg de les capes.

2.2.2.2. Region Adaptative Hierarchical Transform [5]

La principal idea d'aquest mètode és aprofitar els valors d'atribut de nivells de l'arbre més baixos per predir els valors de nivells següents.

Suposem el color com l'atribut a codificar. Comencem en la unitat més petita, els vòxels, que corresponen a les fulles dels arbres anteriorment comentats. Amb els colors d'aquests vòxels obtenim el color d'un volum més gran, l'anterior nivell en l'arbre. No ho fem com a combinació dels 8 vòxels que formen el sub-espai, sinó que ho fem en tres passos, cadascun en una de les tres direccions de l'espai, tal com podem observar a la **¡Error! No se encuentra el origen de la referencia.:**




Figura 9: Exemple de codificació RAHT [5]

D'aquesta manera, es realitza la combinació de colors per parells de vòxels. Cal destacar que treballem des dels vòxels ocupats, però aquests poden tenir parelles que no ho estiguin. Si un dels dos vòxels no està ocupat per cap punt, el valor de l'agrupació resultant serà igual al vòxel que sí conté informació [9].

3. Metodologia en l'exploració i avaluació de codificadors

3.1 Codificadors

Després de la recerca de codificadors per a núvols de punts basats en G-PCC, s'exposen a continuació els dos als quals s'ha pogut tenir accés i amb els que s'ha treballat. A part d'aquests, altres codificadors es descriuen a [10].

Cal comentar, prèviament, que per a l'execució d'aquests s'ha treballat amb Windows Subsystem for Linux, WSL, que permet executar fitxers binaris de Linux de forma nativa a Windows 10. Concretament s'ha treballat amb Ubuntu 18.04.

Aquest sistema no permet l'execució d'aplicacions amb interfície gràfica i, per tant, s'ha utilitzat la connexió a un escriptori remot des de Windows per poder visualitzar l'entorn Ubuntu a través d'una GUI. Sense això no podríem visualitzar els núvols de punts dins del sistema de Linux.

3.1.1. TMC 13, MPEG

És el codificador proposat per MPEGGroup [11]. La compilació del projecte es realitza amb CMake. El llenguatge emprat és C++.

Ofereix moltes possibilitats diferents de compressió, combinant diferents paràmetres:

- Segons la **codificació de la geometria**. Ofereix els dos tipus de codificació de la geometria abans comentats:
 - o Octree
 - o Trisoup
- Segons la **codificació de l'atribut**. Ofereix els dos tipus de codificació d'atribut abans comentats:
 - o Predlift (Predicting and Lifting Transform)
 - o RAHT (Region Adaptative Hierarchical Transform)
- Segons les **pèrdues**. Segons si es codifica amb o sense pèrdues la geometria i/o els atributs, trobem les opcions:
 - o Lossless-geom-lossless-attrs
 - o Lossless-geom-lossy-attrs
 - o Lossless-geom-nearlossless-attrs
 - o Lossy-geom-lossy-attrs

3.1.2. Draco, Google [12]

És el codificador desenvolupat per Google. La compilació del projecte es realitza amb CMake. El llenguatge emprat és C++.

En aquest cas, Draco realitza una compressió geomètrica basada en KD – Tree, similar a Octree, on les subdivisions de l'espai no han de ser estrictament regulars. El software ens ofereix l'elecció de diferents paràmetres. La majoria tenen a veure amb el procés de quantificació:

- *qp*: determina el número de bits amb el que es quantifica la posició dels punts. A major nombre de bits, més valors diferents podrà prendre la posició. Per defecte val 11.
- *qt*: número de bits emprats per quantificar l'atribut de textura o color. Per defecte val 10.
- *qn*: número de bits per la quantificació del vector normal a la superfície. Per defecte val 8.
- *qg*: número de bit per quantificar qualsevol atribut genèric. Per defecte val 8.

A més, ofereix un altre paràmetre per determinar el nivell de compressió, segons el qual varien diferents característiques d'aquesta:

- *cl*: valor comprès entre 0 i 10. Per defecte pren valor 7.

```

roger@DESKTOP-RLTD4F2:/mnt/c/Users/Roger/Desktop/Uni/4B/TFG/draco/build_dir$ ./draco_encoder
Usage: draco_encoder [options] -i input

Main options:
-h | -?          show help.
-i <input>       input file name.
-o <output>      output file name.
-point_cloud    forces the input to be encoded as a point cloud.
-qp <value>     quantization bits for the position attribute, default=11.
-qt <value>     quantization bits for the texture coordinate attribute, default=10.
-qn <value>     quantization bits for the normal vector attribute, default=8.
-qg <value>     quantization bits for any generic attribute, default=8.
-cl <value>     compression level [0-10], most=10, least=0, default=7.
--skip ATTRIBUTE_NAME skip a given attribute (NORMAL, TEX_COORD, GENERIC)
--metadata      use metadata to encode extra information in mesh files.

Use negative quantization values to skip the specified attribute

```

Figura 10: Presentació per pantalla de les opcions de Draco

3.2 Datasets

3.2.1 8iVSLF data set [13]

Aquest dataset conté una seqüència d'un núvol de punts de 300 frames d'alta resolució, així com 6 núvols de punts, d'un sol frame cadascun, d'alta resolució. S'ha capturat el cos sencer de diferents persones amb 39 càmeres RGB sincronitzades configurades a 30 fps, situades a un parell de metres del subjecte. Cada càmera captura per cada clúster un valor RGB i un de profunditat. La fusió de les captures obtingudes amb totes les càmeres conforma el núvol de punts.

S'especifica la resolució espacial dels núvols de punts. Aquests estan continguts en un espai cúbic de 4096 x 4096 x 4096 vòxels, conegut com a *depth 12*, la qual cosa s'especifica en el nom dels arxius, que acaba en "vox12". La majoria dels núvols ocupen gairebé els 4096 vòxels en la seva major dimensió i, per tant, MPEG extreu les dimensions aproximades que representen un vòxel. Suposant les figures amb altura 1.8 m, un vòxel representa un espai físic cúbic de 0.44 mm de costat ($1.8\text{m} / 4096 \text{ voxels} \approx 0.44 \text{ mm}$). Només els vòxels pròxims a la superfície del subjecte es troben ocupats, i els seus atributs són: components RGB de la superfície vista per cada càmera, i les components x,y,z del vector normal del vòxel. Són per tant, núvols de punts d'entre mig i un gigabyte, ja que cada punt emmagatzema molta informació.



Figura 11: Exemples de núvols del dataset d'MPEG [13]

3.2.2 LS3DPC [14]

Aquest conjunt de núvol de punts a gran escala pertany al Visual Information Processing (VIP) Lab de l'UNIST (Ulsan National Institute of Science and Technology), a Corea del Sud. Consisteix en 11 núvols de punts de gran escala que contenen milions de punts, cadascun amb les seves coordenades (x,y,z) en metres i el seu color en RGB. Ha estat capturat per l'escàner LiDAR terrestre RIEGL VZ-400 i la càmera digital Nikon D700 simultàniament [15].





Figura 11: Previsualització de núvols del dataset LS3DPC

3.3 Avaluació dels resultats

Per a l'avaluació qualitativa dels resultats, s'utilitza Meshlab, programa de codi obert que ofereix eines per visualitzar núvols de punts en format .ply. Poder navegar per dins el núvol de punts amb les funcions zoom in i zoom out és clau per poder avaluar els resultats correctament.

La importància de visualitzar els resultats és cabdal, però també necessitem donar mètriques quantitatives d'aquests. Actualment, hi ha diverses propostes per al càlcul de la distorsió geomètrica però, degut al punt actual on es troba la tecnologia Point Cloud, encara no hi ha una mètrica consensuada per al càlcul de la distorsió geomètrica. Avaluarem numèricament, per tant, la distorsió geomètrica, mentre que la fotomètrica es veurà exposada de manera visual.

En imatges 2D s'utilitza l'error quadràtic mitjà MSE i la relació senyal-soroll PSNR. Per al cas dels núvols de punts també les trobem, però degut a la naturalesa dels senyals apareix un nou concepte de distància emprat en el càlcul d'aquestes mesures.

Distància punt a pla

Suposem un punt A d'un núvol de punts. Un cop el núvol és comprimit i descomprimit, aquest punt A del núvol original correspon a un punt B del núvol descodificat. Podria ser que aquests dos estiguessin continguts en la mateixa superfície representada pel núvol de punts. En aquest cas, podríem considerar que no hi ha error degut a la compressió, però la distància punt a punt establiria un error diferent de zero. La distància punt a pla, soluciona aquesta situació.

A continuació s'explica el procediment per al càlcul de la distància punt a pla:

- 1- Per cada punt del núvol de punts original, es busca el punt més pròxim en el núvol de punts descodificat; al qual s'associa.
- 2- Es pren el vector unitari normal a la superfície que s'aproxima associat al punt del núvol original. Si la informació sobre aquest vector no és present al núvol, aquest vector s'estima.
- 3- El vector d'error es calcula com el camí del punt del núvol original al punt del núvol descodificat. Amb això obtindríem l'error amb la distància punt a punt; hem d'anar un pas més enllà.
- 4- Es projecta el vector d'error calculat sobre la direcció del vector normal a la superfície. Aquest nou vector error és el que determina la distància del punt al pla.

5- Finalment, amb aquest vector podem calcular l'error.




Figura 12: Distància de punt a pla [12].

Càlcul de PSNR

La PSNR és la relació senyal-soroll de pic; la màxima energia possible d'una senyal i el soroll que afecta a la seva representació més fidedigna [16].

Abans però, necessitem definir l'error quadràtic mitjà que en funció de la distància utilitzada varia. Sigui A el núvol de punts original i B aquest núvol comprimit i descomprimit, tenim:

MSE amb distància punt a punt

$$e_{A,B}^{punt} = \frac{1}{N_A} \sum_{\forall a_j \in A} \|E(i, j)\|^2$$

On $E(i, j)$ és l'error, la distància punt a punt per a tots els punts del núvol A respecte el punt al qual s'associen al núvol B. N_A és el nombre de punts que conformen el núvol A.

MSE amb la distància punt a pla:

$$e_{A,B}^{pla} = \frac{1}{N_A} \sum_{\forall a_j \in A} (E(i, j) \cdot N_j)^2$$

Amb tot, la PSNR entre el núvol de punts A i B es calcula, en dB, com:

$$PSNR_{A,B} = 10 \log_{10} \frac{p^2}{e_{A,B}}$$

Software per a l'avaluació

De cara a l'avaluació quantitativa de la qualitat, s'ha buscat un software extern als codificadors. D'aquesta manera, assegurem el mateix criteri per ambdós codificadors. El programa en qüestió és escrit per Dong Tian i modificat per Maurice Quach, i l'accés al qual és lliure a través de [17].

El codi ens proporciona, donats dos núvols de punts (l'original i el descodificat) els paràmetres de MSE i PSNR per als casos de les dues distàncies, la distància punt a punt, i la distància punt a pla. El software realitza el càlcul en ambdós sentits, del punt A al B i viceversa. Finalment, el criteri per escollir els resultats simètrics, és escollir el sentit que dona pitjors resultats, PSNR més baixa. Ens fixarem, com hem comentat, en els resultats que s'obtenen fent ús de la distància punt a pla, però s'exposaran també els resultats amb la distància punt a punt, per observar la diferència en la PSNR segons pel tipus de distància utilitzada.

Per a poder realitzar aquests càlculs es necessiten els vectors normals a la superfície aproximada. No tots els núvols de punts contenen aquesta informació, i és per això que aquest programa també s'encarrega de generar-los en cas que el núvol de punts no els tingui [18].

4. Resultats

S'exposen, a continuació, els resultats obtinguts amb cadascun dels codificadors en els seus mètodes de codificació, especificant els paràmetres a analitzar i la mètrica de distorsió utilitzada. Alhora, per a l'avaluació perceptiva es presenten gràficament els diferents núvols de punts obtinguts després del procés de compressió i descompressió.

4.1. Compressió amb TMC13

Geometria

Analitzem la codificació de la geometria. S'analitzen els dos mètodes de codificació de la geometria descrits a l'apartat 3, Octree i Trisoup. Es realitza amb codificació de la geometria i l'atribut en pèrdues, donat que és l'únic tipus de codificació que la tècnica Trisoup permet. Diferents execucions d'un mateix núvol de punts es realitzen variant el paràmetre principal de cada mètode.

En aquest cas, els mètodes empresos són Octree-Predlift i Trisoup-Predlift. Utilitzant RAHT per a la codificació de l'atribut els resultats són els mateixos, ja que estem evaluant la distorsió geomètrica.

El paràmetre principal a variar del mètode Octree és el factor d'escala, comprès entre 0 i 1, relatiu a la quantificació de la posició. Aquest paràmetre escala la geometria del núvol de punts multiplicant cada coordenada per un factor real i arrodonint a presció enter.

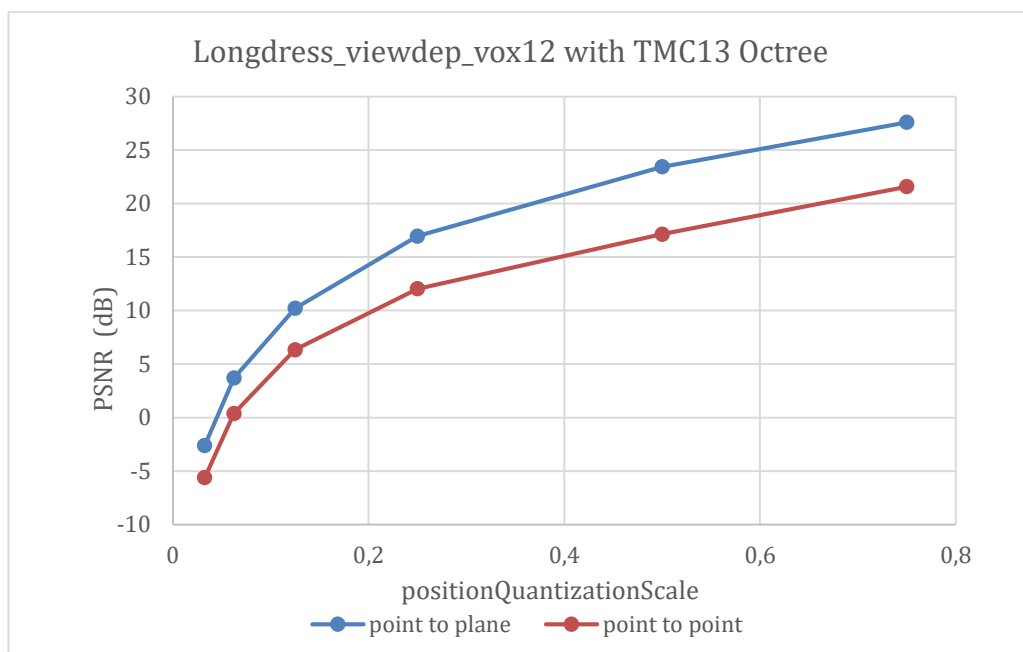


Figura 13: PSNR amb la codificació Octree



Figura 14: Visualització de resultats. TMC13 Octree. D'esquerra a dreta, $positionQuantizationScale = 0.0325, 0.125, 0.75$. A la dreta l'original.

Observem els resultats en diferents punts de l'escala de quantificació de la posició:

En la codificació Trisoup, el paràmetre principal és $trisoupNodeSizeLog2$. Aquest paràmetre fixa la mida del node fins on es desenvolupa l'Octree i a partir del qual es realitza reconstrucció de la superfície basada en triangles.




Figura 15: PSNR amb la codificació Trisoup

En aquest cas, valors baixos permeten una millor reconstrucció amb triangles. Com més es desenvolupa l'Octree, pitjor funciona la tècnica Trisoup.

Observem els resultats amb diferents valors del trisoupNodeSizeLog2:



Figura 16: Visualització de resultats. TMC13 Trisoup. D'esquerra a dreta, trisoupNodeSizeLog2 = 5, 2. A la dreta l'original.

Amb les execucions anteriors podem fer una comparativa interessant entre el mode Octree i Trisoup. Es mostren la PSNR en dB en funció de la mida dels fitxers codificats. En aquest cas, majoritàriament Octree és més eficient. Per obtenir una PSNR d'uns 20 dB, ambdós mètodes aconseguen una compressió al voltant de 1000:1.

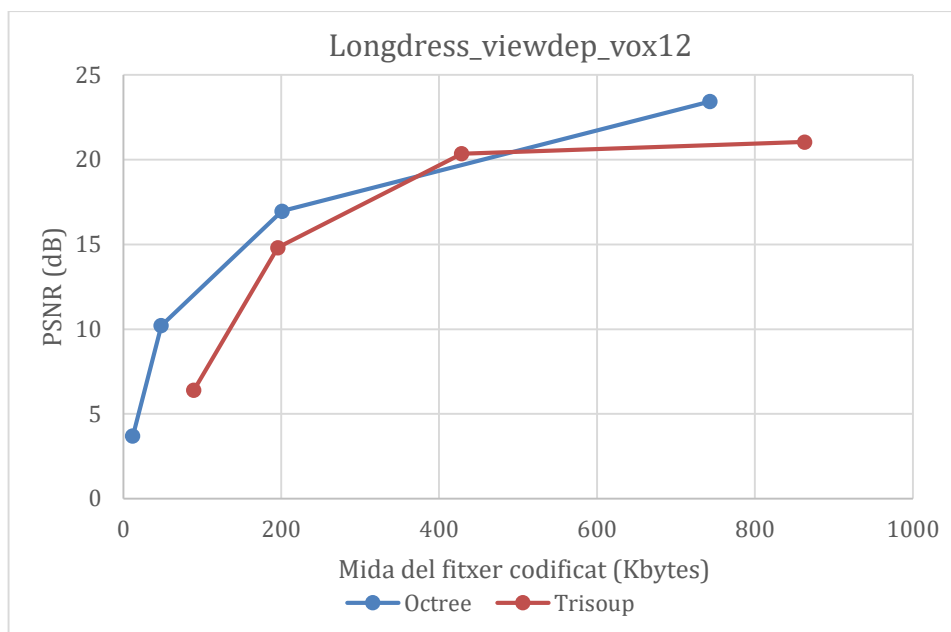


Figura 17: PSNR en funció de la mida del fitxer comprimit. Octree vs Trisoup.

Avaluant l'Octree amb el fitxer soldier_viewdep_vox12.ply en la seva configuració per a la **codificació sense pèrdues**, obtenim un nivell de compressió .La informació del núvol de punts continua intacte. El software d'avaluació ens dona un error MSE nul, i la PSNR per tant, tendeix a infinit. Es corrobora l'absència de pèrdues.



Figura 18: Codificació sense pèrdues. A l'esquerra el núvol original. A la dreta, el resultat.

En quant al tamany dels fitxers partíem d'un fitxer original de 737.917 Mbytes el codificat pesa 4.942 Mbytes. Parlem d'una ràtio de l'ordre 150:1.

Atribut

Per a l'avaluació de l'atribut, visualitzarem els núvols obtinguts amb *octree-predlift* i *octree-raht* per a una mateixa codificació de la geometria. Cercant zones concretes del núvol original on abundin colors pròxims, podrem analitzar els efectes de cada tècnica de codificació de l'atribut.



Figura 19: Resultats codificació atribut. A l'esquerra codificació Predlift. A la dreta RAHT

Com podem observar, és molt complicat trobar diferències entre ambdós resultats i, comparant respecte l'original també. Això ens demostra que la codificació d'atribut està més ben implementada, i la distorsió fotomètrica d'un núvol de punts no causa la degradació que causa la geomètrica a nivell perceptiu.

4.2. Compressió amb Draco

Geometria

Per al núvol de punts soldier_viewdep_vox12.ply de la base de dades 8lvs1f, s'ha fixat el nivell de compressió a 7 i la resta de paràmetres amb els seus valors per defecte anteriorment comentats. Realitzant la compressió i descompressió amb diferent nombre de bits per la quantificació obtenim:




Figura 20: PSNR en funció del bitstream de posició, compressió amb Draco.



Figura 21: Resultats visuals amb diferents mides del bitsteam de posició. A l'esquerra 8 bits, a la dreta 14.

Altres proves interessants són les realitzades amb el núvol de punts two_building.ply, de la base de dades LS3DPC:

- Mida del fitxer codificat respecte el nivell de compressió: El sistema Draco té uns límits de compressió preestablerts que fan que aquesta relació no sigui lineal.




Figura 22: Mida del fitxer en funció del nivell de compressió

L'ús de més bits en la quantificació de les posicions repercuteix, evidentment, en una major qualitat, però també en una major mida del fitxer codificat:




Figura 23: Mida del fitxer en funció de la quantificació de la posició

En quant a temps, en un ordinador i-7 d'usuari convencional, els resultats són els següents:




Figura 24: Temps de codificació i descodificació en funció del nivell de compressió




Figura 25: : Temps de codificació i descodificació en funció del nivell de quantificació de posició.

A nivell de temps de còmput, Draco és més ràpid, competint contra execucions de mig minut en tmc3 en el millor dels casos. El temps però, serà més o menys important en funció de la aplicació que necessitem.

Atribut

Per a l'anàlisi de la qualitat perceptiva sobre l'atribut obtinguda amb Draco, observem les dues imatges següents. En primer lloc, el núvol de punts original, corresponent a l'arxiu two_buildings.ply.



Figura 26: Núvol de punts original, two_building.ply.

En segon lloc, es presenta el núvol de punts comprimit i descomprimit, utilitzant 6 bits per a quantificar l'atribut de color. Observant el terra podem veure que s'han perdut textures, degut a la falta de colors. La línia de rajoles vermelles sobre les taronges ara queda mal representada. De la mateixa manera, el reflex del vidre de l'edifici es troba també molt deteriorat.

Aquestes zones són les més afectades perquè concentren moltes tonalitats d'un mateix color. Quan el núvol de punts es quantifica en atribut, es perden colors i molts punts de colors pròxims passen a prendre el mateix valor.



Figura 27: Compressió amb Draco amb 6 bits per al valor d'atribut.

5. Costos

El salari de l'autor del projecte és de 9 euros l'hora. Tenint en compte que s'ha dedicat 25h per setmana durant 18 setmanes, la retribució total ascendeix a 4050 €.

S'han fet reunions setmanals d'1,5 hores entre autor i supervisor. A més el supervisor ha treballat en la coordinació del projecte 2 hores per setmana. El salari d'aquest és de 30€/h euros l'hora i, per tant, les pertinents retribucions sumen 1890 €.

CONCEPTE	COST
Salari de l'autor	4.050 €
Salari del supervisor	1.890 €
TOTAL	5.940 €

6. Conclusions

Els objectius especificats al principi d'aquest projecte eren l'estudi de la compressió G-PCC, la recerca de diferents codificadors G-PCC, i l'avaluació de ràtios de compressió, latències i pèrdues. Al llarg del projecte s'han assolit aquets objectius.

S'ha estudiat la compressió de núvols de punts basada en geometria. L'assoliment d'aquest coneixement ha estat clau per comprendre la seva implementació, així com les tècniques de codificació de la geometria i de l'atribut.

La recerca de software per no ha estat trivial. Els avenços en el camp de la compressió de núvols de punts s'estan produint a la actualitat i part de la informació encara no és accessible per a tothom. Tot i així s'ha aconseguit trobar codi proposats per diferents experts, amb els quals s'ha pogut realitzar les proves necessàries per avaluar-los i extreure conclusions.

Degut al context anteriorment descrit, tampoc ha estat senzill aconseguir bases de dades i mètriques objectives d'avaluació. La gran majoria de bases de dades són d'accés restringit i poques compleixen els requisits del projecte. Finalment però se n'han utilitzat dues, una per núvols de punts de subjectes i una altra per espais oberts, amb núvols més dispersos, menys densos. Pel que fa a les mètriques emprades, la primera publicació al respecte és recent [12] i només mesura distorsió de geometries. Les mètriques que combinen simetria i color són encara més recents (2019, 2020) i els codis disponibles han donat problemes d'execució amb els datasets emprats en aquest projecte.

Com s'ha comentat a l'apartat de resultats, els diferents mètodes per a la compressió de núvols de punts, poden ser més o menys útils en funció de si es vol conservar amb major prioritat la geometria o l'atribut. Tots ells, però, tenen un fet en comú. La llarga duració del procés. La compressió i descompressió de la informació requereix d'un temps elevat, arribant a desenes de minuts en el pitjor dels casos. Independentment de la qualitat d'aquests resultats doncs, podem concloure que no són algorismes per a aplicacions en temps real.

És just, per tant, extreure valoracions deixant de banda el temps de computació. Sempre trobarem un compromís entre qualitat i nivell de compressió. Aquest serà resolt de manera diferent en funció de l'aplicació, on a vegades interessarà conservar al màxim la qualitat, i altres vegades voldrem un alt nivell de compressió encara que el núvol perdi força qualitat.

En quant als codificadors, queda palès que el TMC13 d'MPEG ofereix moltes més possibilitats a l'usuari per a realitzar la codificació que desitgi, involucrant molts més

paràmetres modificables i moltes tècniques de compressió. En l'aspecte de l'eficiència, queda més ben situat Draco, que aconsegueix realitzar la compressió més ràpidament i amb nivells de relació senyal soroll PSNR superiors.

Una altra idea important és la importància de la codificació geomètrica. Com s'ha pogut observar amb claredat als resultats, la distorsió geomètrica afecta substancialment més que la fotomètrica en la percepció visual que tenim del núvol de punts. Quantificant amb un nombre molt menor de bits l'atribut, els resultats visuals continuen sent molt bons, essent complicat en certs casos detectar diferències. Les tècniques predictives de la codificació d'atribut contribueixen a aquesta conservació del color. La distorsió geomètrica, per tant, és la principal, i amb la que s'ha de seguir treballant per al desenvolupament de sistemes més eficients.

Finalment, per a futurs projectes, s'hauria de continuar investigant sobre aquestes tecnologies, ja que estan en continu moviment, la informació és molt nova, i l'estat de l'art del moment en que es reprengui contemplarà nous mètodes.

Fins i tot, fent ús de hardware professional, amb processadors i memòries RAM adients, es podrien crear dos mòduls de ROS per al sistema i veure si alguna de les implementacions de codificadors proposades podrien funcionar en temps real. Així, aquestes tècniques podrien millorar sistemes que necessitessin compressions molt ràpides, com un sistema de telepresència 3D.

Bibliografia:

- [1] «Why MPEG made two codecs for Point Cloud Compression? – MPEG 3D Graphics». <https://3dgraphics.mpeg.expert/2020/12/why-mpeg-made-two-codecs-for-pcc/specifications/> (consulta maig 24, 2021).
- [2] S. Schwarz *et al.*, «Emerging MPEG Standards for Point Cloud Compression», *IEEE J. Emerg. Sel. Top. Circuits Syst.*, vol. 9, núm. 1, p. 133-148, març 2019, doi: 10.1109/JETCAS.2018.2885981.
- [3] «Reference Software in MPEG – MPEG 3D Graphics». <https://3dgraphics.mpeg.expert/2020/11/reference-software-in-mpeg/software/> (consulta maig 04, 2021).
- [4] D. Thery i B. Katz, «Anechoic audio and 3D video content database of small ensemble performance for virtual concerts», set. 2019.
- [5] D. Graziosi, O. Nakagami, S. Kuma, A. Zaghetto, T. Suzuki, i A. Tabatabai, «An overview of ongoing point cloud compression standardization activities: video-based (V-PCC) and geometry-based (G-PCC)», *APSIPA Trans. Signal Inf. Process.*, vol. 9, ed 2020, doi: 10.1017/ATSIP.2020.12.
- [6] A. F. R. Guarda, N. M. M. Rodrigues, i F. Pereira, «Adaptive Deep Learning-Based Point Cloud Geometry Coding», *IEEE J. Sel. Top. Signal Process.*, vol. 15, núm. 2, p. 415-430, feb. 2021, doi: 10.1109/JSTSP.2020.3047520.
- [7] E. Torlig, E. Alexiou, T. A. Fonseca, R. L. de Queiroz, i T. Ebrahimi, «A novel methodology for quality assessment of voxelized point clouds», en *Applications of Digital Image Processing XLI*, 2018, vol. 10752, p. 107520l. doi: 10.1117/12.2322741.
- [8] A. Dricot i J. Ascenso, «Adaptive Multi-level Triangle Soup for Geometry-based Point Cloud Coding», en *2019 IEEE 21st International Workshop on Multimedia Signal Processing (MMSp)*, set. 2019, p. 1-6. doi: 10.1109/MMSp.2019.8901791.
- [9] R. L. de Queiroz i P. A. Chou, «Compression of 3D Point Clouds Using a Region-Adaptive Hierarchical Transform», *IEEE Trans. Image Process.*, vol. 25, núm. 8, p. 3947-3956, ago. 2016, doi: 10.1109/TIP.2016.2575005.
- [10] NJUVISION, *NJUVISION/PCGCv2*. 2021. Consulta: juny 19, 2021. [En línia]. Disponible a: <https://github.com/NJUVISION/PCGCv2>
- [11] *MPEGGroup/mpeg-pcc-tmc13*. MPEGGroup, 2021. Consulta: juny 21, 2021. [En línia]. Disponible a: <https://github.com/MPEGGroup/mpeg-pcc-tmc13>
- [12] *google/draco*. Google, 2021. Consulta: juny 16, 2021. [En línia]. Disponible a: <https://github.com/google/draco/blob/75b82f7b68c797b4e0ff5e73ca8a81e2db3db797/README.md>
- [13] «8i Voxelized Surface Light Field (8iVSLF) Dataset – MPEG Point Cloud Compression». <https://mpeg-pcc.org/index.php/pcc-content-database/8i-voxelized-surface-light-field-8ivslf-dataset/> (consulta juny 14, 2021).
- [14] «UNIST LS3DPC Dataset – VIP Lab, UNIST». <https://vip.unist.ac.kr/large-scale-3d-point-clouds-dataset-for-virtual-point-removal/> (consulta juny 12, 2021).
- [15] J.-S. Yun i J.-Y. Sim, «Virtual Point Removal for Large-Scale 3D Point Clouds with Multiple Glass Planes», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 43, núm. 2, p. 729-744, feb. 2021, doi: 10.1109/TPAMI.2019.2933818.

- [16] «Peak signal-to-noise ratio», *Wikipedia*. juny 19, 2021. Consulta: juny 21, 2021. [En línia]. Disponible a: https://en.wikipedia.org/w/index.php?title=Peak_signal-to-noise_ratio&oldid=1029394318
- [17] M. Quach, *mauriceqch/geo_dist*. 2021. Consulta: juny 14, 2021. [En línia]. Disponible a: https://github.com/mauriceqch/geo_dist
- [18] D. Tian, H. Ochimizu, C. Feng, R. Cohen, i A. Vetro, «Geometric distortion metrics for point cloud compression», en *2017 IEEE International Conference on Image Processing (ICIP)*, set. 2017, p. 3460-3464. doi: 10.1109/ICIP.2017.8296925.

Annexes

Distribució dels paquets de treball (workpackages)

Projecte: Lectura d'informació	WP ref: WP1
Tasca principal: Obtenció d'informació	
Breu descripció: Obtenció d'informació sobre el tema a partir de diversos articles suggerits pel supervisor.	Inici: 22/02/2021 Final: 17/03/2021
Tasca interna T1: Llegir articles sobre MPEG-PCC. Tasca interna T2: Llegir "Deep Implicit Volume Compression" Tasca interna T3: Llegir "Emerging MPEG Stds for PCC"	

Projecte: Recerca de software i núvols de punts	WP ref: WP2
Tasca principal: Prototip del software	
Breu descripció: Buscar codificadors i datasets amb els que avaluar el comportament d'aquests.	Inici: 17/03/2021 Final: 26/04/2021
Tasca interna T1: Buscar datasets de núvols de punts variats. Tasca interna T2: Exploració de codificadors.	

Project: Test i Anàlisi	WP ref: WP3
Tasca principal: Realització de proves	
Breu descripció: Realitzar proves amb els diferents codificadors i les seves diferents configuracions sobre els núvols de punts trobats. Elecció dels paràmetres d'avaluació (ràtios de compressió, latència).	Inici: 01/04/2021 Final: 03/05/2021
Tasca interna T1: Compilar i executar les implementacions de codificadors trobades. Tasca interna T2: Elecció dels paràmetres i realització de proves.	

Project: Avaluació	WP ref: WP4
---------------------------	--------------------

Tasca principal: Conclusions	
Breu descripció: Comparar resultats entre els codificadors per extreure conclusions sobre els seus rendiments.	Inici: 26/04/2021 Final: 20/05/2021
Tasca interna T1: Benchmarking de les implementacions. Tasca interna T2: Avaluació i comparatives.	

Project: Documentació	WP ref: WP5	
Tasca principal: Redacció de documents i entregables		
Breu descripció: Escriure i entregar en les dates establertes tota la documentació requerida al llarg del desenvolupament del TFG.	Inici: 01/03/2021 Final: 18/06/2021	
Tasca interna T1: Proposta i planificació del projecte Tasca interna T2: Revisió Crítica del projecte Tasca interna T3: Memòria Final del projecte	Entregables: Un document per cada tasca.	Dates: 16/03 14/04 21/06

Fites

WP#	Tasca#	Títol curt	Fita	Data
2	2	Exploració de codificadors	Trobar, almenys, dos codificadors.	26/04/2021
3	1	Compilació i execució	Realització del test.	03/05/2021


La compressió de núvols de punts és un tema punter, on els avenços s'estan produint actualment. Això resulta en escassos recursos disponible (i encara menys accessible per tothom), especialment de seqüències de núvols de punts.

La recerca d'aquestes bases de dades s'ha vist afectada per aquesta situació i, per tant, s'han realitzat modificacions respecte la proposta de treball inicial, prolongant les dates dels paquets de treball.

Canvis:

- Extensió del temps dedicat als paquets de treball 2 i 3.
- Posposició del paquet de treball 4 dues setmanes.

Diagrama de Gantt



Glossari

G-PCC = Geometry-based Point Cloud Compression

PredLift = Prediction + Lifting

RAHT = Region Adaptive Hierarchical Transform

MSE = Mean Square Error

PSNR = Peak Signal to Noise Ratio

Trisoup = Triangle Soup

8iVSLF = 8i Voxelized Surface Light Field

UNIST = Ulsan National Institute of Science and Technology

TFG = Treball Final de Grau