



**HAL**  
open science

## Évaluation sans référence de la qualité des nuages de points via la saillance visuelle 3D

Salima Bourbia, Ayoub Karine, Aladine Chetouani, Maher Jridi, Mohammed El  
Hassouni

### ► To cite this version:

Salima Bourbia, Ayoub Karine, Aladine Chetouani, Maher Jridi, Mohammed El Hassouni. Évaluation sans référence de la qualité des nuages de points via la saillance visuelle 3D. ORASIS 2025, ISEN Yncréa Ouest, Jun 2025, Le Croisic, France. <hal-05142176>

**HAL Id: hal-05142176**

**<https://hal.science/hal-05142176v1>**

Submitted on 3 Jul 2025

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire HAL, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



HAL Authorization

# Évaluation sans référence de la qualité des nuages de points via la saillance visuelle 3D

Salima Bourbia<sup>1,2</sup> Ayoub Karine<sup>3</sup> Aladine Chetouani<sup>4</sup> Maher Jridi<sup>2</sup> Mohammed El Hassouni<sup>1</sup>

<sup>1</sup> FLSH, FSR, Mohammed V University in Rabat, Rabat, Morocco

<sup>2</sup> L@bISEN, Vision-AD, ISEN Yncréa Ouest campus Nantes, Carquefou, France

<sup>3</sup> Université Paris Cité, LIPADE, F-75006 Paris, France

<sup>4</sup> Laboratoire L2TI - Sup Galilée, Université Sorbonne Paris Nord, Campus de Villetaneuse, Paris, France

## Résumé

L'évaluation de la qualité des nuages de points sans référence (en anglais, No-Reference Point Cloud Quality Assessment : NR-PCQA) vise à estimer la qualité perceptuelle d'un nuage de points sans nécessiter de référence, en se rapprochant du jugement humain. Cependant, la plupart des approches existantes n'exploitent pas pleinement les informations visuelles perçues par l'observateur, alors qu'elles jouent un rôle clé dans l'évaluation de la qualité. Dans cet article, nous proposons une nouvelle méthode NR-PCQA intégrant la saillance visuelle 3D afin d'améliorer l'estimation de la qualité. Nous générons d'abord une carte de saillance 3D, qui sert à pondérer le nuage de points en accordant une importance accrue aux régions perceptuellement significatives, celles qui captent spontanément l'attention humaine. Le nuage de points pondéré obtenu est ensuite analysé par un encodeur 3D, qui traite directement les points pour prédire un score objectif de qualité. Les expérimentations menées sur deux bases de données publiques de PCQA montrent que notre approche surpasse la majorité des méthodes existantes.

## Mots Clef

Nuage de points, saillance visuelle 3D, évaluation sans références de la qualité.

## Abstract

No-Reference Point Cloud Quality Assessment (NR-PCQA) aims to estimate the perceptual quality of a point cloud without requiring a reference, in a manner that aligns with human judgment. However, most existing approaches do not effectively incorporate human visual information, despite its crucial role in quality evaluation. In this paper, we propose a novel NR-PCQA method that leverages 3D visual saliency to enhance quality estimation. First, we generate a 3D saliency map, which is used to weight the point cloud, emphasizing perceptually significant regions that naturally draw human attention. After that, the salient point cloud is then processed by a 3D encoder that directly analyzes the points to predict an

objective quality score. Experimental results on two public PCQA datasets demonstrate that our approach outperforms the majority of the state-of-the-art methods.

## Keywords

Point cloud, 3D visual saliency, blind quality assessment.

## 1 Introduction

Le développement rapide des nuages de points 3D (en anglais, Point clouds : PCs) a stimulé des progrès dans divers domaines d'application, notamment le métavers et la communication immersive par médias. Néanmoins, le processus de génération de PCs soulève des défis potentiels concernant la qualité visuelle perçue des données 3D. Des facteurs externes tels que les paramètres de balayage, le bruit lors de l'acquisition ou de la transmission, ainsi que les dégradations géométriques dues à la simplification et à la compression, entre autres, peuvent affecter la qualité globale [1].

Pour relever ces défis, les méthodes d'évaluation de la qualité des nuages de points (en anglais, Point Cloud Quality Assessment : PCQA) sont indispensables pour évaluer la qualité visuelle perçue des PCs traités. La littérature distingue deux approches principales en PCQA : subjective et objective [2]. L'évaluation subjective repose sur l'observation humaine, où plusieurs participants notent la qualité des PCs, ce qui permet d'obtenir des scores d'opinion moyenne, notés comme MOS. Bien que cette méthode soit considérée comme la plus fiable et robuste, elle demeure coûteuse, chronophage et peu adaptée aux applications à grande échelle en raison des ressources nécessaires. En revanche, l'évaluation objective vise à automatiser la prédiction de la qualité, constituant une alternative prometteuse.

En fonction de la disponibilité d'un PC de référence (non dégradé), les méthodes objectives d'évaluation de la qualité se classent en trois catégories : les approches avec Référence Complète (en anglais, Full-Reference : FR), avec Référence Réduite (en anglais, Reduced-Reference : RR) et Sans Référence (en anglais, No-Reference : NR).

Les méthodes FR et RR exploitent respectivement un accès total ou partiel aux informations de référence pour mesurer la similarité entre le PC dégradé et son équivalent de référence, afin d'évaluer sa qualité. Toutefois, dans de nombreuses applications pratiques, un PC de référence n'est pas disponible, rendant ainsi les méthodes NR, qui ne nécessitent aucune information de référence, particulièrement adaptées aux applications du monde réel. Bien que plusieurs méthodes PCQA aient été proposées, les solutions existantes ne parviennent souvent pas à établir une corrélation avec le comportement du Système Visuel Humain (SVH) lors de l'évaluation.

Motivés par cette limitation, nous proposons d'intégrer la saillance visuelle 3D dans la PCQA, afin d'identifier les régions perceptuellement significatives, qui captent immédiatement l'attention du SVH. Nous faisons l'hypothèse que, dans l'évaluation de la qualité des PCs, les distorsions affectant les régions les plus saillantes sont plus susceptibles d'être perçues comme gênantes par le SVH, altérant ainsi la perception globale et les jugements de qualité. Sur la base de cette hypothèse, nous proposons une méthode NR intégrant la saillance visuelle 3D dans l'évaluation de la qualité des PCs. Plus précisément, nous commençons par générer une carte de saillance 3D à partir du PC. Ensuite, chaque PC est pondéré par sa carte de saillance correspondante pour obtenir un PC saillant. Ce dernier est ensuite introduit dans un encodeur 3D, qui extrait les caractéristiques de dégradation afin de prédire la qualité visuelle perçue.

Le reste de l'article est organisé comme suit : dans la section 2, nous présentons les travaux de l'état de l'art. Dans la section 3, nous détaillons le modèle proposé. Dans la section 4, nous présentons les résultats expérimentaux, incluant une étude d'ablation. Enfin, une conclusion est donnée dans la section 5.

## 2 État de l'art

L'évaluation de la qualité des PCs peut être abordée selon deux principales stratégies : les méthodes basées sur la projection et celles basées sur les points.

Les méthodes basées sur l'image évaluent la qualité des PCs en les projetant sur des plans 2D depuis plusieurs points de vue, puis en analysant la qualité des images obtenues. Dans les approches FR, la qualité est estimée en comparant les projections des PCs de référence et dégradés. Queiroz *et al.* [3] ont utilisé des projections orthogonales pour mapper les PCs de référence et dégradés sur six vues correspondant aux faces d'un cube englobant le PC. Le PSNR a ensuite été utilisé pour estimer la qualité perçue des images projetées. Alexiou *et al.* [4] ont étudié l'impact du nombre de vues projetées sur la performance du modèle. Leurs résultats ont montré qu'une augmentation du nombre de vues ne garantit pas nécessairement une meilleure précision des prédictions de qualité perçue. Au-delà de l'utilisation des images en texture couleur, plusieurs études ont intégré des cartes

liées à la géométrie, telles que les cartes de profondeur et de courbure, afin d'améliorer la robustesse des métriques basées sur la projection comme dans ces travaux [5, 6]. Dans les méthodes RR, Zhou *et al.* [7] propose une méthode RR, qui utilise des cartes de saillance 2D et utilisent des mesures de similarité statistique entre les cartes de référence et dégradées. Dans les approches NR, Liu *et al.* [8] ont développé le modèle PQA-Net, qui traite des images 2D projetées à l'aide d'un réseau de neurone profond conçu pour deux sous-tâches : la classification des types de distorsion et la prédiction de la qualité pour les PCs affectés par des distorsions indépendantes. Bourbia *et al.* [9] ont mené une étude approfondie sur l'impact des réseaux de neurones pré-entraînés sur la performance de la prédiction de qualité. Fan *et al.* [10] ont proposé de représenter les PCs sous forme de séquences vidéo et d'appliquer des techniques avancées d'évaluation de la qualité des vidéos pour prédire la qualité des PCs.

Contrairement aux méthodes basées sur les projections, les méthodes basées sur les points évaluent la qualité directement sur l'ensemble des points du PC. Les premières approches proposées dans la littérature incluent les métriques Point-to-Point (P2Point) [11], Point-to-Plane (P2Plane) [12] et Plane-to-Plane (Plane2Plane) [13], conçues pour quantifier les dégradations géométriques des PCs. Ces méthodes reposent sur le calcul de la distance entre des points ou des plans correspondants entre des objets de référence et dégradés. Afin de prendre en compte les distorsions colorimétriques, les auteurs de [14] ont proposé une métrique P2Point pour la couleur, opérant dans l'espace colorimétrique YCbCr. Cette métrique suit un principe similaire aux métriques P2Point appliquées à la géométrie, en calculant la distance entre les valeurs de couleur des PCs d'origine et dégradé. De manière similaire, Torgil *et al.* [15] utilisent la métrique Color-YUV PSNR pour quantifier la distance colorimétrique entre les points de référence et évalués dans l'espace colorimétrique YUV. Meynet *et al.* [16] proposent la méthode PC-MSDM, inspirée de la métrique SSIM. Cette approche mesure la similarité structurelle en analysant les statistiques de courbure calculées à partir des voisinages locaux correspondants entre les PCs de référence et dégradés. Yang *et al.* [1] introduisent la métrique GraphSIM, qui repose sur l'extraction de points-clés obtenus par un rééchantillonnage du PC de référence. Des graphes locaux sont ensuite construits autour de ces points-clés pour les versions de référence et dégradées. L'indice de qualité est alors déterminé en comparant la similarité des graphes entre les PCs analysés. Viola *et al.* [17] présentent une méthode RR qui extrait diverses caractéristiques géométriques et colorimétriques des PCs originaux et dégradés. Ces caractéristiques sont ensuite utilisées du côté du récepteur pour évaluer les dégradations dans le PC. Dans les méthodes NR, Zhang *et al.* [18] utilisent un ensemble de paramètres statistiques représentant les statistiques de scènes naturelles des PCs

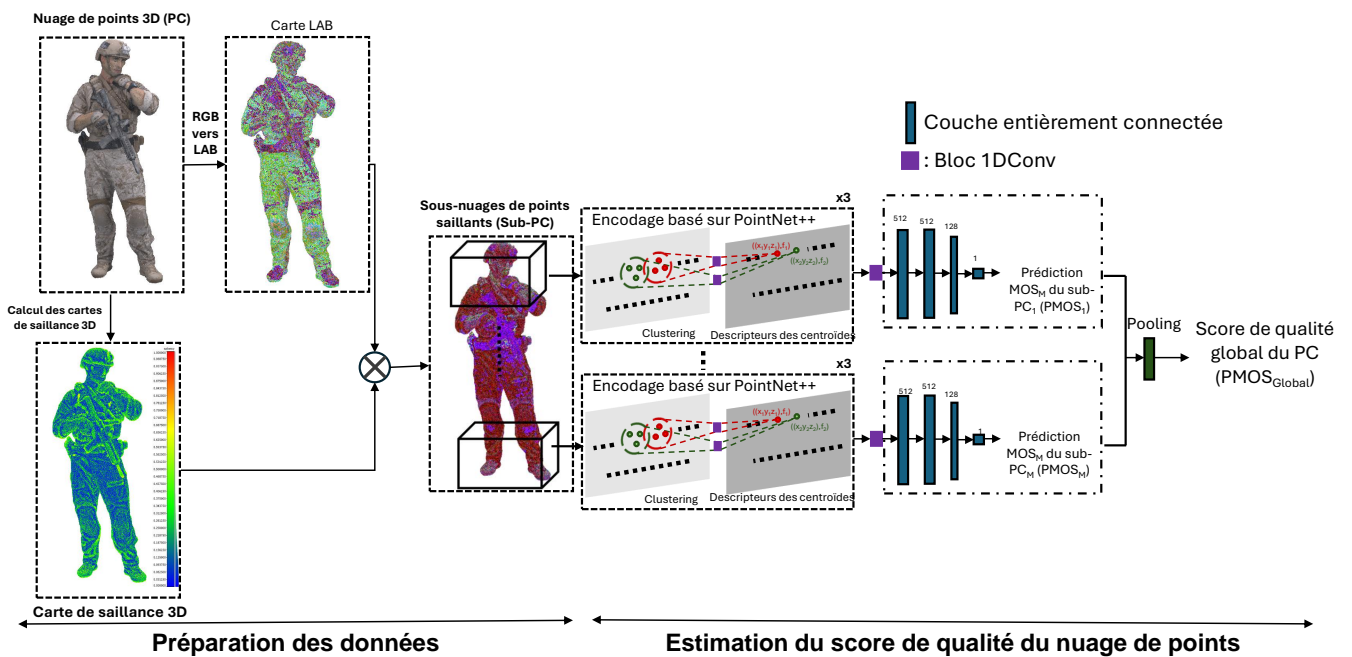


FIGURE 1 – Le schéma de la méthode proposée est structuré comme suit. Dans un premier temps, nous convertissons l’information colorimétrique du nuage de points 3D (PC) en espace LAB à partir de son canal RGB. Ensuite, nous appliquons une pondération du nuage de points en fonction de sa carte de saillance 3D correspondante, à l’aide d’une multiplication point par point. Le nuage de points saillant est alors segmenté en plusieurs sous-nuages de points. Ces sous-nuages saillants sont ensuite traités par un encodeur afin d’extraire les caractéristiques des dégradations 3D et d’estimer la qualité visuelle. Enfin, le score de qualité global du nuage de points est obtenu en agrégeant les scores prédits pour chaque sous-nuage saillant.

dégradés. Ces paramètres sont ensuite intégrés dans un modèle d’apprentissage automatique pour l’évaluation. Dans [19], un réseau multi-flux est proposé pour capturer la dégradation géométrique des PCs. Tliba *et al.* [20] proposent une approche basée sur l’extraction aléatoire de patches de PCs compressés, évalués à l’aide d’un modèle profond, la qualité globale étant dérivée par moyennage des scores.

### 3 Méthode proposée

Dans cette section, nous introduisons une nouvelle approche pour l’évaluation de la qualité visuelle des PCs basée sur la saillance visuelle 3D, comme illustré dans la figure 1. Inspirée des travaux fondamentaux sur l’évaluation de la qualité des images [21], notre méthodologie repose sur l’hypothèse que les distorsions affectant les régions les plus saillantes d’un PC sont plus perceptibles et ont un impact évident sur la qualité visuelle. Par conséquent, nous supposons que ces zones saillantes méritent une importance accrue dans l’évaluation globale de la qualité visuelle perçue. Inspirés par cette observation, nous exploitons la saillance visuelle en ajustant les attributs du PC via une pondération basée sur sa carte de saillance 3D. Ensuite, le PC saillant résultant est traité

par un encodeur 3D afin d’extraire les caractéristiques de dégradation et de prédire sa qualité visuelle. Les sous-sections suivantes décrivent en détail les différentes étapes du modèle proposé.

#### 3.1 Prétraitement des données

**Calcul des cartes de saillance 3D.** Pour identifier les régions perceptuellement significatives d’un PC, nous adoptons la méthode proposée dans [22]. Cette approche attribue un score de saillance à chaque point, reflétant ainsi son importance dans la structure globale du PC et son rôle dans la reconnaissance des motifs clés. Comme illustré dans figure 2, son application sur l’objet LongDress de la base de données SJTU [2] met en évidence les régions les plus saillantes, telles que le nez, les yeux et les cheveux. L’un des principaux avantages de cette méthode est sa capacité à générer des cartes de saillance directement à partir des points du PC, sans nécessiter d’étape de projection, évitant ainsi toute perte d’information. La génération de ces cartes repose sur l’entraînement d’un réseau de neurone basé sur les points pour une tâche de classification spécifique. Une fois le modèle pré-entraîné, il est utilisé pour produire les cartes de saillance via un processus de rétropropagation. La contribution de chaque

point est alors déterminée proportionnellement à sa perte de gradient, calculée comme la différence entre les pertes de prédiction du PC avec et sans ce point. Grâce à cette approche, il est possible d’obtenir des cartes de saillance pour des PCs dégradés, permettant d’évaluer l’influence de chaque point dans la reconnaissance du modèle.

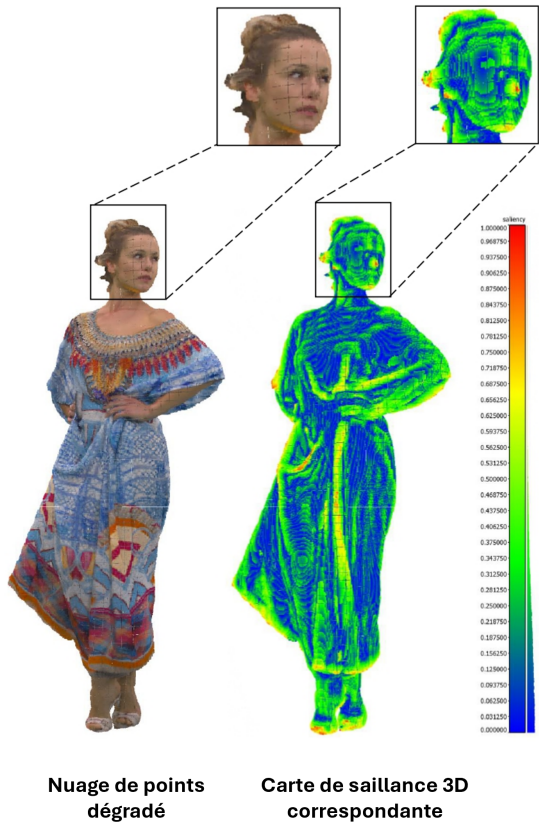


FIGURE 2 – Nuage de points dégradé avec sa carte de saillance visuelle 3D correspondante provenant de la base de données SJTU.

**Pondération par saillance et découpage dynamique des nuages de points.** Les PCs sont généralement encodés dans l’espace colorimétrique RGB. Cependant, cet espace ne reflète pas toujours fidèlement la perception humaine des couleurs, ce qui peut introduire des imprécisions dans leur évaluation. Pour remédier cette limitation, une approche couramment adoptée consiste à convertir les données RGB dans l’espace colorimétrique CIELAB [23], qui offre une représentation plus proche de la perception visuelle humaine. Cette conversion permet une meilleure correspondance entre les variations de couleur des PCs et la perception naturelle des observateurs. Inspirés par les travaux en évaluation de la qualité des images 2D [24], qui exploitent des cartes de saillance pour pondérer les images, nous généralisons ce principe à l’évaluation des PCs. Pour ce faire, nous intégrons la saillance visuelle dans le processus d’évaluation en pondérant la carte LAB du PC par sa carte de saillance correspondante via une

multiplication point par point. Cette pondération nous permet d’accorder une plus grande importance aux régions saillantes par rapport aux autres zones.

Dans les bases de données de PCQA, la densité des points varie en fonction de la qualité visuelle des objets. Les objets de haute résolution comportent souvent plusieurs millions de points, rendant une évaluation directe avec des modèles d’apprentissage profond particulièrement coûteuse en ressources. Les stratégies courantes, telles que le sous-échantillonnage ou le découpage aléatoire, peuvent altérer la structure spatiale et ne pas capturer l’ensemble des distorsions présentes dans le PC, compromettant ainsi la précision de l’évaluation. Pour surmonter ces limitations sans affecter la fidélité des données, nous proposons de diviser les PCs saillants en sous-PCs saillants. Le nombre de sous-PCs générés est ajusté dynamiquement afin de s’adapter aux variations de densité des objets. Ensuite, nous procédons à une normalisation locale des coordonnées et des attributs de ces sous-PCs avant de les introduire dans l’encodeur 3D proposé. Cette approche garantit une analyse détaillée et une meilleure prise en compte des distorsions affectant la qualité visuelle perçue des PCs.

### 3.2 Estimation de la qualité visuelle des nuages de points

Après l’extraction des sous-PCs saillants, nous utilisons un encodeur basé sur les points afin de capturer leurs caractéristiques de qualité perceptuelle. Nous proposons une architecture inspirée de PointNet++ [25], en raison de sa capacité à extraire hiérarchiquement des informations locales et globales. L’encodeur proposé commence par regrouper les points d’entrée et leur couleur saillante associée en clusters locaux se chevauchant, en se basant sur la proximité spatiale. Pour le clustering, nous utilisons l’algorithme des  $k$ -plus proches voisins (kNN) avec un rayon spécifique. Ensuite, chaque groupe local est traité par un bloc composé de convolutions 1D à poids partagés et d’opérations de max pooling, conçues pour l’apprentissage des motifs locaux. Cette procédure est répétée trois fois afin d’obtenir un ensemble complet de caractéristiques locales. Ces caractéristiques sont ensuite introduites dans un perceptron multicouche (en anglais, multilayer perceptron : MLP) pour générer une représentation de dimension supérieure, encapsulant efficacement les caractéristiques de dégradation pertinentes des sous-PCs saillants. L’encodage obtenu est ensuite transmis à un ensemble de couches entièrement connectées de tailles 512, 512 et 128, respectivement, suivies d’une fonction d’activation *ReLU*. Enfin, le score de qualité visuelle des sous-PCs saillants est obtenu via une dernière couche utilisant une fonction d’activation *Sigmoid*.

Pour optimiser les paramètres du modèle, nous minimisons la distance  $L_1$  entre les scores subjectifs normalisés (*MOS*) et les scores prédits (*PMOS*), définie comme suit :

$$\mathcal{L}_{quality} = \frac{1}{N} \sum_{i=1}^N PMOS_i - MOS_i \quad (1)$$

où  $N$  représente la taille du batch.

Le score final de qualité du PC dégradé est obtenu en agrégeant les scores de qualité de l'ensemble des sous-PCs saillants. Plus précisément, la qualité globale est calculée en moyennant les scores prédits pour tous les  $M$  sous-PCs, comme défini dans équation 2 :

$$PMOS_{global} = \frac{1}{M} \sum_{i=1}^M PMOS_i \quad (2)$$

## 4 Résultats expérimentaux

### 4.1 Description des bases de données

Pour évaluer notre méthode en comparaison avec l'état de l'art, nous utilisons deux bases de données largement utilisées dans la littérature : ICIP2020 [26] et SJTU [2], décrites ci-dessous :

- **ICIP2020** [26] : Cette base contient 90 PCs dégradés, dérivés de 6 objets de référence, dont quatre objets complets et deux objets partiellement couverts représentant des corps humains. Les objets dégradés sont obtenus à partir de trois types de compression : G-PCC Octree, G-PCC Trisoup et V-PCC.
- **SJTU** [2] : Cette base est composée de 9 PCs de référence, incluant à la fois des objets de corps humains et des objets inanimés, avec leurs 378 versions dégradées correspondantes. Chaque PC de référence est altéré par 4 types de distorsions indépendantes : compression basée sur Octree, bruit de couleur, bruit gaussien géométrique et sous-échantillonnage. De plus, 3 types de distorsions mixtes sont inclus : réduction d'échelle & bruit de couleur, réduction d'échelle & bruit gaussien géométrique, et bruit de couleur & bruit gaussien géométrique.

### 4.2 Métriques d'évaluation et protocole de validation

La performance du modèle est évaluée à l'aide de deux métriques : le Coefficient de Corrélation par Rang de Spearman (SROCC) et le Coefficient de Corrélation Linéaire de Pearson (PLCC). Le SROCC mesure la monotonie des prédictions du modèle, tandis que le PLCC évalue leur précision. Pour ces deux métriques, une valeur absolue proche de 1 indique une meilleure capacité du modèle à prédire la qualité perçue des PCs.

Pour évaluer l'efficacité de notre approche et la comparer aux méthodes de l'état de l'art, nous utilisons un protocole de validation croisée en  $K$ -fold. Plus précisément, nous appliquons une validation croisée en 6-fold sur la base de données ICIP2020 et en 9-fold sur la base SJTU. Chaque fold comprend toutes les versions dégradées

d'un même objet de référence. Dans ce protocole, un fold est utilisé comme ensemble de test, un autre comme ensemble de validation, et les folds restants comme ensemble d'entraînement. Il est important de noter qu'aucun chevauchement n'existe entre ces ensembles, garantissant ainsi une évaluation impartiale et réduisant les biais liés au contenu. Les résultats finaux sont obtenus en moyennant les métriques de performance sur l'ensemble des folds, permettant ainsi une évaluation plus stable et représentative des performances du modèle.

Type	Méthodes	SROCC	PLCC
FR	P2Point MSE [11]	0.946	0.934
	P2Point PSNR [11]	0.868	0.855
	P2Point Hausdorff MSE [11]	0.401	0.531
	P2Point Hausdorff PSNR [11]	0.548	0.456
	P2Plane PSNR [12]	0.913	0.910
	P2Plane Hausdorff MSE [12]	0.534	0.613
	P2Plane Hausdorff PSNR [12]	0.580	0.547
	Plane2Plane MSE [13]	0.925	0.912
	Color-y MSE [14]	0.925	0.910
	Color-y PSNR-y [14]	0.887	0.892
	PointSSIM [27]	0.676	0.564
	IW-SSIM [28]	0.910	0.897
GraphSIM [1]	0.931	0.893	
RR	PCMRR [17]	0.723	0.887
NR	Tliba <i>et al.</i> [20]	0.908	<b>0.955</b>
	<b>Méthode proposée</b>	<b>0.950</b>	<b>0.955</b>

TABLE 1 – Résultats comparatifs obtenus par validation croisée en 6-fold sur la base de données ICIP2020. Les meilleures corrélations sont indiquées en gras, tandis que les deuxièmes meilleures sont soulignées.

Type	Méthodes	SROCC	PLCC
FR	P2Point MSE [11]	0.729	0.812
	P2Point Hausdorff MSE [11]	0.715	0.775
	P2Plane MSE [12]	0.495	0.565
	P2Plane Hausdorff MSE [12]	0.460	0.375
	Color-yuv PSNR [15]	0.795	0.817
	Plane2Plane MSE [13]	0.529	0.658
	PCQM [29]	0.742	0.777
	PC-MSDM [16]	0.324	0.412
	PointSSIM [27]	0.686	0.713
	GraphSIM [1]	0.878	0.844
	RR	PCMRR [17]	0.470
NR	3D-NSS [18]	0.714	0.738
	Fan <i>et al.</i> [30]	0.832	0.861
	PQA-Net [31]	0.713	0.683
	IT-PCQA [32]	0.561	0.621
	<b>Méthode proposée</b>	<b>0.911</b>	<b>0.917</b>

TABLE 2 – Résultats comparatifs obtenus par validation croisée en 9-fold sur la base de données SJTU. Les meilleures corrélations sont indiquées en gras, tandis que les deuxièmes meilleures sont soulignées.

### 4.3 Évaluation des performances et comparaison

Pour évaluer la performance de notre modèle par rapport aux méthodes de l'état de l'art, nous effectuons une étude comparative avec les approches FR, RR et NR sur les bases de données ICIP2020 et SJTU. Les résultats expérimentaux sont présentés respectivement dans tableau 1 et tableau 2. Les meilleures corrélations sont mises en gras, et les deuxièmes meilleures corrélations sont soulignées.

Sur la base de données ICIP2020 (tableau 1), la méthode proposée surpasse la majorité des approches de comparaison et présente une forte corrélation avec les scores subjectifs, atteignant le meilleur score SROCC de 0.950 et partageant le meilleur score PLCC de 0.955 avec la méthode NR proposée par Tliba *et al.* [20].

Sur la base de données SJTU (tableau 2), nous observons une diminution des performances par rapport à celles obtenues sur ICIP2020, en particulier pour certaines méthodes FR classiques telles que la métrique P2Plane MSE. Cette baisse peut être attribuée à la nature des distorsions présentes dans la base SJTU, qui inclut à la fois des distorsions individuelles et mixtes. Ces types de dégradations sont plus complexes que les artefacts de compression présents dans ICIP2020. Toutefois, notre méthode proposée offre des résultats cohérents et affiche les meilleures corrélations, atteignant 0.911 en SROCC et 0.917 en PLCC. Ces résultats soulignent la pertinence de notre approche par rapport aux métriques de l'état de l'art.

### 4.4 Étude d'ablation

Pour approfondir la compréhension de notre méthode, nous réalisons une étude d'ablation sur la plus grande base de données, SJTU, comme présenté dans tableau 3. Cette analyse vise à évaluer l'impact de chaque composant sur les performances de notre approche.

Dans un premier temps, nous étudions l'effet de la conversion des attributs RGB du PC vers l'espace colorimétrique CIELAB (LAB dans tableau 3). Cette conversion permet une séparation explicite des informations de luminance et de chrominance, ce qui est plus représentatif de la perception humaine des couleurs. Afin de démontrer son importance, nous entraînons le modèle proposé avec et sans conversion en espace CIELAB. Comme illustré dans tableau 3, cette conversion facilite l'extraction de caractéristiques plus robustes, conduisant ainsi à une meilleure prédiction de la qualité. Ensuite, nous analysons l'impact de la pondération par la carte de saillance. Pour cela, nous entraînons le modèle proposé en appliquant indépendamment la multiplication de la carte de saillance sur les représentations RGB et LAB. Comme indiqué dans tableau 3, l'intégration de cette étape améliore significativement les performances du modèle, comme en montrent les valeurs élevées des coefficients SROCC et PLCC. Ces résultats valident notre hypothèse selon laquelle l'exploitation de la saillance visuelle, qui met en avant les régions d'intérêt perceptif élevé, améliore

l'évaluation de la qualité des PCs et permet une extraction plus efficace des caractéristiques pertinentes.

Entrée	SROCC	PLCC
(XYZ, RGB)	0.891	0.850
(XYZ, LAB)	0.930	0.922
(XYZ, RGB × Saillance)	0.955	0.941
(XYZ, LAB × Saillance)	<b>0.957</b>	<b>0.951</b>

TABLE 3 – Étude d'ablation sur les différents composants du modèle proposé sur la base de données SJTU.

## 5 Conclusion

Dans cette étude, nous avons proposé une nouvelle approche sans référence intégrant la saillance visuelle afin d'améliorer l'évaluation de la qualité visuelle des nuages de points. En exploitant les cartes de saillance 3D, nous pondérons les nuages de points, mettant ainsi en évidence les régions d'intérêt qui captent l'attention visuelle humaine. Ensuite, le nuage de points saillant obtenu est traité par un encodeur 3D basé sur les points afin de prédire la qualité perçue. Nous avons mené des évaluations approfondies sur deux bases de données de référence, ICIP2020 et SJTU, et comparé notre modèle aux approches existantes avec référence complète, référence réduite et sans référence. De plus, une étude d'ablation a été réalisée afin d'analyser l'impact de chaque composant de notre modèle. Les résultats expérimentaux démontrent que l'intégration de la saillance visuelle améliore significativement la corrélation avec les scores subjectifs humains, surpassant la majorité des métriques de comparaison. Ces observations confirment que la prise en compte des régions d'intérêt perceptuelles est un facteur clé pour une évaluation plus fidèle de la qualité visuelle des nuages de points.

## Références

- [1] Q. Yang, Z. Ma, Y. Xu, Z. Li, and J. Sun, "Inferring point cloud quality via graph similarity," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 6, pp. 3015–3029, 2022.
- [2] Q. Yang, H. Chen, Z. Ma, Y. Xu, R. Tang, and J. Sun, "Predicting the perceptual quality of point cloud : A 3d-to-2d projection-based exploration," *IEEE Transactions on Multimedia*, pp. 1–1, 2020.
- [3] R. L. De Queiroz and P. A. Chou, "Motion-compensated compression of dynamic voxelized point clouds," *IEEE Transactions on Image Processing*, vol. 26, no. 8, pp. 3886–3895, 2017.
- [4] E. Alexiou and T. Ebrahimi, "Exploiting user interactivity in quality assessment of point cloud imaging," in *2019 Eleventh International Conference*

- on *Quality of Multimedia Experience (QoMEX)*. IEEE, 2019, pp. 1–6.
- [5] Q. Yang, H. Chen, Z. Ma, Y. Xu, R. Tang, and J. Sun, “Predicting the perceptual quality of point cloud : A 3d-to-2d projection-based exploration,” *IEEE Transactions on Multimedia*, vol. 23, pp. 3877–3891, 2020.
- [6] Z. He, G. Jiang, Z. Jiang, and M. Yu, “Towards a colored point cloud quality assessment method using colored texture and curvature projection,” in *2021 IEEE International Conference on Image Processing (ICIP)*. IEEE, 2021, pp. 1444–1448.
- [7] W. Zhou, G. Yue, R. Zhang, Y. Qin, and H. Liu, “Reduced-reference quality assessment of point clouds via content-oriented saliency projection,” *IEEE Signal Processing Letters*, vol. 30, pp. 354–358, 2023.
- [8] Q. Liu, H. Yuan, H. Su, H. Liu, Y. Wang, H. Yang, and J. Hou, “Pqa-net : Deep no reference point cloud quality assessment via multi-view projection,” *IEEE transactions on circuits and systems for video technology*, vol. 31, no. 12, pp. 4645–4660, 2021.
- [9] S. Bourbia, A. Karine, A. Chetouani, M. El Hassouni, and M. Jridi, “No-reference 3d point cloud quality assessment using multi-view projection and deep convolutional neural network,” *IEEE Access*, vol. 11, pp. 26 759–26 772, 2023.
- [10] Z. Zhang, W. Sun, Y. Zhu, X. Min, W. Wu, Y. Chen, and G. Zhai, “Treating point cloud as moving camera videos : A no-reference quality assessment metric,” *arXiv e-prints*, pp. arXiv–2208, 2022.
- [11] E. Alexiou, I. Viola, T. M. Borges, T. A. Fonseca, R. L. De Queiroz, and T. Ebrahimi, “A comprehensive study of the rate-distortion performance in mpeg point cloud compression,” *APSIPA Transactions on Signal and Information Processing*, vol. 8, p. e27, 2019.
- [12] D. Tian, H. Ochimizu, C. Feng, R. Cohen, and A. Vetro, “Geometric distortion metrics for point cloud compression,” in *2017 IEEE International Conference on Image Processing (ICIP)*, 2017, pp. 3460–3464.
- [13] E. Alexiou and T. Ebrahimi, “Point cloud quality assessment metric based on angular similarity,” in *2018 IEEE International Conference on Multimedia and Expo (ICME)*, 2018, pp. 1–6.
- [14] R. Mekuria, S. Laserre, and C. Tulvan, “Performance assessment of point cloud compression,” in *2017 IEEE Visual Communications and Image Processing (VCIP)*. IEEE, 2017, pp. 1–4.
- [15] E. M. Torlig, E. Alexiou, T. A. Fonseca, R. L. de Queiroz, and T. Ebrahimi, “A novel methodology for quality assessment of voxelized point clouds,” in *Applications of Digital Image Processing XLI*, vol. 10752. SPIE, 2018, pp. 174–190.
- [16] G. Meynet, J. Digne, and G. Lavoué, “Pc-msdm : A quality metric for 3d point clouds,” in *2019 Eleventh International Conference on Quality of Multimedia Experience (QoMEX)*. IEEE, 2019, pp. 1–3.
- [17] I. Viola and P. Cesar, “A reduced reference metric for visual quality evaluation of point cloud contents,” *IEEE Signal Processing Letters*, vol. 27, pp. 1660–1664, 2020.
- [18] Z. Zhang, W. Sun, X. Min, T. Wang, W. Lu, and G. Zhai, “No-reference quality assessment for 3d colored point cloud and mesh models,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 32, no. 11, pp. 7618–7631, 2022.
- [19] S. Bourbia, A. Karine, A. Chetouani, M. El Hassouni, and M. Jridi, “Multi-stream point-based model for blind geometric point cloud quality assessment,” in *Proceedings of the 20th International Conference on Content-based Multimedia Indexing*, 2023, pp. 224–228.
- [20] M. Tliba, A. Chetouani, G. Valenzise, and F. Dufaux, “Representation learning optimization for 3d point cloud quality assessment without reference,” in *2022 IEEE International Conference on Image Processing (ICIP)*. IEEE, 2022, pp. 3702–3706.
- [21] W. Zhang, A. Borji, Z. Wang, P. Le Callet, and H. Liu, “The application of visual saliency models in objective image quality assessment : A statistical evaluation,” *IEEE transactions on neural networks and learning systems*, vol. 27, no. 6, pp. 1266–1278, 2015.
- [22] T. Zheng, C. Chen, J. Yuan, B. Li, and K. Ren, “Pointcloud saliency maps,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019, pp. 1598–1606.
- [23] T. Chen, X. Yang, N. Li, T. Wang, and G. Ji, “Underwater image quality assessment method based on color space multi-feature fusion,” *Scientific Reports*, vol. 13, no. 1, p. 16838, 2023.
- [24] X. Feng, T. Liu, D. Yang, and Y. Wang, “Saliency based objective quality assessment of decoded video affected by packet losses,” in *2008 15th IEEE International Conference on Image Processing*. IEEE, 2008, pp. 2560–2563.
- [25] C. R. Qi, L. Yi, H. Su, and L. J. Guibas, “Pointnet++ : Deep hierarchical feature learning on point sets in a metric space,” *Advances in neural information processing systems*, vol. 30, 2017.
- [26] S. Perry, H. P. Cong, L. A. da Silva Cruz, J. Prazeres, M. Pereira, A. Pinheiro, E. Dunic, E. Alexiou, and T. Ebrahimi, “Quality evaluation of static point clouds encoded using mpeg codecs,” in *2020*

*IEEE International Conference on Image Processing (ICIP)*, 2020, pp. 3428–3432.

- [27] E. Alexiou and T. Ebrahimi, “Towards a point cloud structural similarity metric,” in *2020 IEEE International Conference on Multimedia Expo Workshops (ICMEW)*, 2020, pp. 1–6.
- [28] Q. Liu, H. Su, Z. Duanmu, W. Liu, and Z. Wang, “Perceptual quality assessment of colored 3d point clouds,” *IEEE Transactions on Visualization and Computer Graphics*, 2022.
- [29] G. Meynet, Y. Nehmé, J. Digne, and G. Lavoué, “Pcqm : A full-reference quality metric for colored 3d point clouds,” in *2020 Twelfth International Conference on Quality of Multimedia Experience (QoMEX)*, 2020, pp. 1–6.
- [30] Y. Fan, Z. Zhang, W. Sun, X. Min, N. Liu, Q. Zhou, J. He, Q. Wang, and G. Zhai, “A no-reference quality assessment metric for point cloud based on captured video sequences,” in *2022 IEEE 24th International Workshop on Multimedia Signal Processing (MMSP)*. IEEE, 2022, pp. 1–5.
- [31] Q. Liu, H. Yuan, H. Su, H. Liu, Y. Wang, H. Yang, and J. Hou, “Pqa-net : Deep no reference point cloud quality assessment via multi-view projection,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 31, no. 12, pp. 4645–4660, 2021.
- [32] Q. Yang, Y. Liu, S. Chen, Y. Xu, and J. Sun, “No-reference point cloud quality assessment via domain adaptation,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022, pp. 21 179–21 188.