

# Un indice d'évaluation sans référence basé sur l'apprentissage profond pour l'évaluation de la qualité des maillages 3D colorés

Zaineb IBORK<sup>1,2</sup> Anass NOURI<sup>1,2</sup> Olivier LÉZORAY<sup>2</sup> Christophe CHARRIER<sup>2</sup>

<sup>1</sup>Laboratoire SETIME, Faculté des Sciences, Université Ibn Tofail, Kénitra, Maroc

<sup>2</sup>Université de Caen Normandie, ENSICAEN, CNRS, Normandie Univ, GREYC UMR 6072, F-14000, Caen, France

**Résumé** – Dans cette étude, nous avons proposé une nouvelle approche pour évaluer la qualité visuelle des maillages 3D colorés sans référence, comblant ainsi une lacune importante dans la littérature. Notre méthode, CMDQA, exploite des caractéristiques profondes extraites des projections 2D des maillages et de leurs patches, combinées à l'indice de qualité d'image sans référence BRISQUE. Grâce à des expériences approfondies sur la base de données CMDM, nous avons démontré l'efficacité de notre approche pour prédire la qualité globale et avons prouvé sa supériorité par rapport aux métriques existantes (avec ou sans référence) de l'état de l'art.

**Abstract** – The rise of 3D data has transformed industries by enabling precise simulations and realistic visualizations. However, noise and data loss during generation and transmission make quality assessment essential. While existing research addresses 3D point clouds and meshes separately, assessing 3D colored meshes remains a challenge due to the lack of reference datasets. This paper introduces a No-Reference 3D Colored Mesh Visual Quality Assessment (CMVQA) approach, leveraging geometric, color, and spatial features from mesh projections. Extensive experiments show its superior performance compared to full-reference metrics, including image quality assessment algorithms.

## 1 Introduction

L'essor des données 3D a révolutionné des secteurs comme l'architecture, l'ingénierie, la santé et le divertissement, permettant des simulations précises et des visualisations réalistes. Cette avancée stimule l'innovation dans la réalité virtuelle, l'impression 3D et la CAO. Cependant, les données 3D sont sujettes au bruit géométrique/colorimétrique et aux pertes dues à la compression, rendant l'évaluation de leur qualité essentielle pour garantir précision et utilisabilité. Les données 3D existent principalement sous deux formes : les nuages de points et les maillages. Bien que les deux aient été étudiés pour l'évaluation de la qualité, les maillages offrent une meilleure qualité visuelle grâce à leur structure de surface. Cet article propose une approche sans référence pour évaluer la qualité des maillages 3D colorés.

Dans la littérature, plusieurs approches ont été proposées pour l'estimation sans référence de la qualité des maillages 3D [1–3, 5, 6, 8, 12]. Toutes ces approches considèrent des maillages non-colorés. De plus, les distorsions utilisées pour construire une base de maillages colorés pour l'évaluation sont basées sur des perturbations géométriques indépendantes liées au bruit, au lissage et à la compression. Par conséquent, il existe un fossé dans la littérature pour l'estimation de la qualité des maillages 3D colorés dû à l'absence de vérité terrain de la qualité des maillages colorés. Heureusement, Nehme *et al.* ont récemment proposé la première base d'évaluation de la qualité des maillages colorés [11] appelée CMDM. Les mêmes auteurs ont proposé une approche avec référence d'évaluation de la qualité des maillages 3D.

Dans ce papier, nous proposons d'adapter notre travail de recherche récent [8] pour l'évaluation sans référence de la qualité des maillages 3D couleurs. Pour cela, nous étendons notre travail précédent en considérant les combinaisons ap-

prises de plusieurs indices de qualité extraits à l'échelle de vues 2D projetées et à l'échelle de patches de celles-ci. Dans ce qui suit, nous introduisons l'approche proposée et présentons ses résultats puis nous concluons.

## 2 Evaluation sans référence de la qualité des maillages 3D colorés

### 2.1 Pipeline de l'approche

Afin d'évaluer la qualité d'un maillage 3D coloré, notre méthode intitulée CMVQA (*Colored Mesh Visual Quality Assessment*), commence par générer plusieurs projections 2D (nommées vues). Chaque vue est ensuite divisée en 4 patches avec superposition. Ces derniers sont mis en entrée d'un réseau de neurones convolutionnel VGG16 afin d'en extraire des caractéristiques profondes qui sont ensuite utilisées par un régresseur MLP (*Multi-Layer Perceptron*) pour prédire la qualité du maillage en se basant sur son MOS (*Mean Opinion Score*). Pour améliorer ce score, nous introduisons dans le processus la métrique BRISQUE destinée à l'évaluation sans référence de la qualité des images 2D [9]. Le score de qualité prédit final, PMOS (*Predicted Mean Opinion Score*), est calculé par la moyenne ou par une régression non-linéaire. L'approche proposée est basée sur un travail précédent sur l'évaluation de la qualité des maillages non-coloré basée sur des caractéristiques convolutionnelles profondes [8].

### 2.2 Construction des projections 2D

L'objectif est de générer plusieurs vues de chaque maillage 3D  $M_i$  d'une base contenant  $N$  maillages. Afin d'assurer un positionnement cohérent, les centroïdes des maillages sont déplacés vers l'origine du système de coordonnées. Ensuite, chaque maillage est rendu à partir de 11 différents points de

vues en ajustant l'azimut ( $\theta_a$ ) et les angles d'élévation ( $\theta_e$ ) incrémenté par  $\pi/3$  (60 degrés). Les vues obtenues notées  $V_i^j$  sont croppées et redimensionnées en 512x512. Ensuite, quatre patches de taille 288 x 288 avec overlap sont extrais à partir de chaque vue 2D. Cette stratégie permet d'améliorer les informations extraites en comparaison avec d'autres méthodes utilisant des patches plus petits [3]. Les patches extraits des vues  $V_i^j$  d'un maillage  $M_i$  sont notés  $P_i^{j,k}$  avec  $j \in [1, 11]$  et  $k \in [1, 4]$ . Finalement, une normalisation globale est opérée aux patches afin d'optimiser le processus d'évaluation de la qualité.

### 2.3 Estimation de la qualité d'une vue 2D

Dans la phase de pré-traitement, nous avons dérivé deux bases à partir de la base de maillages 3D initiale  $\mathcal{B}$  comprenant  $N$  maillages : 1)  $\mathcal{B}_V$ , contenant les vues 2D entières et 2)  $\mathcal{B}_P$  qui contient les patches. La base  $\mathcal{B}_V = V_i^j$  est composée de  $N \times 11$  images, avec  $i$  allant de 1 à  $N$  et  $j$  allant de 1 à 11. Par ailleurs, l'ensemble de données  $\mathcal{B}_P = P_i^{j,k}$  comprend  $N \times 11 \times 4$  images, où  $i$  varie de 1 à  $N$ ,  $j$  de 1 à 11, et  $k$  de 1 à 4. Pour simplifier la notation, nous représenterons une image de l'ensemble  $\mathcal{B}_S$  par  $I_i^j$ , où  $S$  peut être soit  $V$  soit  $P$ ,  $i$  varie de 1 à  $N$ ,  $j$  varie de 1 à  $N_S$ , et  $N_V = 11$  tandis que  $N_P = 44$ .

Notre objectif est d'évaluer la qualité des projections 2D, en utilisant le score moyen d'opinion (MOS - Mean Opinion Score) du maillage correspondant comme référence. Pour ce faire, nous utilisons un réseau de neurones convolutionnel VGG16 pré-entraîné [13] afin d'extraire des caractéristiques profondes de chaque image  $I_i^j$  redimensionnée à  $224 \times 224$ . En notant l'extracteur de caractéristiques par  $\phi$ , celui-ci transforme l'image d'entrée en un vecteur aplati de taille 25088. Chaque image  $I_i^j$  de l'ensemble de données  $\mathcal{B}_S$  est ainsi représentée par le vecteur de caractéristiques  $\phi(I_i^j)$ , servant d'entrée à un réseau de neurones perceptron multicouche (MLP) peu profond. L'objectif est de prédire un score de qualité proche du MOS du maillage associé  $M_i$ . Avec des ensembles de données séparés pour les vues ( $\mathcal{B}_V$ ) et les patches ( $\mathcal{B}_P$ ), deux régresseurs MLP distincts, notés  $\text{MLPR}_S$ , sont entraînés pour estimer les scores de qualité. Le score d'opinion moyen prédit pour chaque image (PIMOS)  $I_i^j$  est obtenu par  $\text{PIMOS}_S(I_i^j) = \text{MLPR}_S(\phi(I_i^j))$ , où  $S$  indique si  $I_i^j$  est une vue ( $V$ ) ou un patch ( $P$ ), et  $i, j$  parcourent les ensembles de données respectifs. Par ailleurs, étant donné que les projections 2D sont des images, une autre piste à explorer est celle des métriques d'évaluation de la qualité d'image sans référence (No-Reference Image Quality Assessment, IQA). L'une de ces métriques, BRISQUE (Blind/Referenceless Image Spatial Quality Evaluator), pré-entraînée, se distingue dans la littérature [9]. Le score de qualité d'une vue/patch prédit par BRISQUE est noté comme  $\text{PIMOS}_S^B(I_i^j) = \text{BRISQUE}_S(I_i^j)$ , où  $S \in V, P$ ,  $i \in [1, N]$ , et  $j \in [1, N_S]$ .

### 2.4 CMVQA

Une fois qu'un régresseur  $\text{MLPR}_S$  a été entraîné sur un ensemble de données  $\mathcal{B}_S$ , un vecteur de  $N_S$  scores de qualité basés sur des images est obtenu pour chaque maillage  $M_i$  :  $\mathbf{PQ}_S(M_i) = [\text{PIMOS}_S(I_i^j) : j \in [1, N_S]]^T$ . Un vecteur similaire de scores peut être obtenu avec l'indice IQA BRISQUE :  $\mathbf{PQ}_{S,B}(M_i) = [\text{PIMOS}_S^B(I_i^j) : j \in [1, N_S]]^T$ . Enfin, comme nous avons deux ensembles de données  $\mathcal{B}_S$  pour les vues et

les patches, nous obtenons quatre vecteurs différents selon que les évaluateurs de qualité 2D sont appliqués aux vues ou aux patches :

- $\mathbf{PQ}_V(M_i)$  pour les scores de qualité avec  $\text{MLPR}_V$  sur les vues,
- $\mathbf{PQ}_P(M_i)$  pour les scores de qualité avec  $\text{MLPR}_P$  sur les patches des vues,
- $\mathbf{PQ}_{V,B}(M_i)$  pour les scores de qualité avec BRISQUE sur les vues,
- $\mathbf{PQ}_{P,B}(M_i)$  pour les scores de qualité avec BRISQUE sur les patches des vues.

Pour estimer la qualité d'un maillage  $M_i$ , une stratégie de fusion est nécessaire pour agréger tous les scores  $\mathbf{PQ}_{S,*}(M_i)$  en un score unique qui quantifie la qualité globale du maillage. Ce score final de qualité prédite d'un maillage est intitulé *Predicted Mesh Mean Opinion Square*, noté PMMOS. Nous considérons deux stratégies d'agrégation : 1) une basée sur la moyenne et 2) une régression non linéaire par un MLP. Ces deux approches seront appliquées sur un vecteur de scores de qualité  $\mathbf{PQ}$ .

La première méthode d'agrégation, avec la moyenne, peut s'exprimer comme suit :

$$\overline{\text{PMMOS}}(M_i) = \frac{1}{|\mathbf{PQ}|} \sum_{j=1}^{|\mathbf{PQ}|} \mathbf{PQ}^j(M_i) \quad (1)$$

avec  $\mathbf{PQ}^j$  le  $j$ -ième élément du vecteur  $\mathbf{PQ}$ , et  $|\mathbf{PQ}|$  la cardinalité de  $\mathbf{PQ}$ .

La seconde méthode d'agrégation, utilisant un régresseur non linéaire MLP, peut être exprimée comme suit :

$$\text{PMMOS}(M_i) = \text{MLPR}(\mathbf{PQ}(M_i)) \quad (2)$$

Jusqu'à présent, nous n'avons pas mentionné quels sont les éléments constituant le vecteur  $\mathbf{PQ}$ . Nous pourrions simplement utiliser les scores de qualité des vues et des patches séparément, mais nous pourrions également tirer pleinement parti des deux en les utilisant ensemble. Par conséquent, nous étudierons les configurations suivantes :

- $\mathbf{PQ}(M_i) = \mathbf{PQ}_V(M_i)$  : le vecteur de 11 scores de qualité estimés à partir des vues avec  $\text{MLPR}_V$
- $\mathbf{PQ}(M_i) = \mathbf{PQ}_P(M_i)$  : le vecteur de 44 scores de qualité estimés à partir des patches des vues avec  $\text{MLPR}_P$
- $\mathbf{PQ}(M_i) = \mathbf{PQ}_V(M_i) \cup \mathbf{PQ}_P(M_i)$  : le vecteur de 55 scores de qualité estimés à partir des vues et des patches des vues avec  $\text{MLPR}_V$  et  $\text{MLPR}_P$
- $\mathbf{PQ}(M_i) = \mathbf{PQ}_{V,B}(M_i)$  : le vecteur de 11 scores de qualité estimés à partir des vues avec BRISQUE
- $\mathbf{PQ}(M_i) = \mathbf{PQ}_{P,B}(M_i)$  : le vecteur de 44 scores de qualité estimés à partir des patches des vues avec BRISQUE.
- $\mathbf{PQ}(M_i) = \mathbf{PQ}_{V,B}(M_i) \cup \mathbf{PQ}_{P,B}(M_i)$  : le vecteur de 55 scores de qualité estimés à partir des vues et des patches des vues avec BRISQUE.
- $\mathbf{PQ}(M_i) = \mathbf{PQ}_V(M_i) \cup \mathbf{PQ}_P(M_i) \cup \mathbf{PQ}_{V,B}(M_i) \cup \mathbf{PQ}_{P,B}(M_i)$  : le vecteur de 110 scores de qualité estimés à partir des vues et des patches des vues avec  $\text{MLPR}_V$ ,  $\text{MLPR}_P$ , et BRISQUE.

Toutes ces configurations donneront lieu à différentes méthodes CMVQA que nous comparerons dans la section suivante.



FIGURE 1 : Les maillages 3D colorés de la base CMDM. De haut en bas et de gauche à droite : Samourai, Fish, Ari, Chaemleon, Aix

## 3 Résultats expérimentaux

### 3.1 Dataset

Nous réalisons notre évaluation expérimentale sur la base de données CMDM, la seule disposant actuellement d'un MOS comme vérité terrain dans l'état de l'art concernant les maillages 3D colorés [11]. Cet ensemble de données comprend cinq modèles sources (voir Figure 1) soumis à des distorsions géométriques et colorimétriques. Les distorsions incluent une quantification géométrique uniforme, une quantification uniforme des couleurs en espace LAB, une simplification sans prise en compte des couleurs et une simplification prenant en compte les couleurs, chacune avec quatre niveaux d'intensité différents. Au total, la base de données CMDM contient 80 modèles déformés, chacun étant associé à cinq scores de qualité subjectifs basés sur différents points de vue et types d'animations. Pour obtenir un score de qualité unique par maillage, nous calculons la moyenne de ses scores subjectifs.

### 3.2 Métriques d'évaluation de performance

Pour évaluer la performance de nos scores moyen prédits PMOS par rapport à la vérité terrain fournie dans la base de données, nous utilisons deux critères. Premièrement, nous utilisons le Coefficient de Corrélation Linéaire de Pearson (PLCC) pour mesurer la précision des prédictions. Deuxièmement, nous utilisons le Coefficient de Corrélation de Rang de Spearman (SROCC) pour évaluer la monotonie des prédictions. Des valeurs plus élevées de PLCC et SROCC indiquent une meilleure corrélation avec la perception visuelle humaine.

### 3.3 Apprentissage et protocole d'évaluation

#### 3.3.1 Apprentissage des MLPRs

Pour l'estimation de la qualité des projections 2D, l'architecture du régresseur MLP (MLPR<sub>S</sub>) comporte une seule couche cachée avec 512 neurones, utilisant une fonction d'activation *Rectified Linear Unit* (ReLU). Une régularisation par *dropout out* avec un taux de 0,5 est appliquée pour éviter le sur-apprentissage. L'initialisation des poids est effectuée en utilisant la méthode *Glorot* uniforme. L'entraînement est réalisé en utilisant l'erreur moyenne (*Mean Average Error (MAE)*) comme fonction de perte et l'optimiseur RMSprop avec un taux d'apprentissage fixe de 0,001. Un *batch size* égale à un tiers de la taille de l'ensemble d'entraînement a été identifié comme optimal pour obtenir les meilleurs scores de corrélation. La technique *Early Stopping* est utilisée pour la régularisation et pour améliorer la généralisation du modèle.

En ce qui concerne l'agrégation des scores de qualité d'image, un autre régresseur MLP (MLPR) est employé, éga-

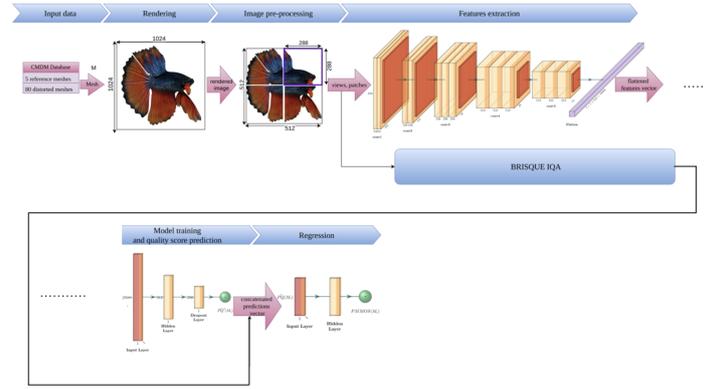


FIGURE 2 : Illustration de l'approche proposée CMVQA.

lement composé d'une seule couche cachée avec une activation ReLU et une couche de sortie avec activation sigmoïde. Le nombre de neurones dans la couche cachée est égal au nombre d'entrées (c'est-à-dire  $|\mathbf{PQ}|$ ). La procédure d'entraînement pour tous les régresseurs est désignée par "*Base Model (BM)*".

Afin d'évaluer la précision des MLPR<sub>S</sub>, nous utilisons une procédure *Leave-One-Model-Out Cross-Validation (LOMO-CV)*.

#### 3.3.2 Configurations évaluées

Différentes configurations en fonction de la manière dont le vecteur  $\mathbf{PQ}$  est formé ont été discutée plus haut. Sa taille peut varier de 11 (uniquement les vues), 44 (uniquement les patches), 55 (vues et patches) jusqu'à 110 (vues, patches et scores BRISQUE). Pour distinguer et comparer ces configurations, nous utiliserons une convention de dénomination spécifique. Les différentes configurations utilisées pour concevoir CMDQA seront indiquées par des termes séparés par des tirets :

$$\text{CMDQA} \quad - \quad \left| \begin{array}{c} A \\ R \end{array} \right| \quad - \quad \left| \begin{array}{c} VPB \\ VP \\ P \\ V \end{array} \right|$$

où la première partie fait référence au schéma d'agrégation (A pour Average Aggregation c'est-à-dire, Eq.1, R pour MLP Regression c'est-à-dire, Eq.2), et la deuxième partie précise comment les scores de qualité agrégés sont obtenus : V fait référence aux scores de qualité provenant des vues, P aux scores de qualité provenant des patches, VP aux scores de qualité provenant à la fois des views et des patches, et VPB aux scores de qualité provenant des vues et des patches avec l'ajout des scores BRISQUE. Lors de l'utilisation exclusive de BRISQUE, les configurations sont désignées comme suit :

$$\text{BRISQUE} \quad - \quad \left| R \right| \quad - \quad \left| \begin{array}{c} VP \\ P \\ V \end{array} \right|$$

Pour BRISQUE, nous utiliserons exclusivement la régression MLP pour l'agrégation des scores. Ces configurations permettront d'évaluer la performance de BRISQUE IQA uniquement pour CMVQA. Les différentes configurations sont illustrées dans la Figure 2 (uniquement pour l'agrégation par régression MLPR).

Type	IQA	Moyenne	
		SROOC	PLCC
No-Reference	NR-SVR [4]	0,449	0,608
	NR-GRNN [5]	0,695	0,660
	NR-CNN [6]	0,502	0,520
	3D-NSS [14]	0,875	0,863
	NIQUE [10]	0,477	0,406
	BRISQUE [9]	0,488	0,579
	GMS-3DQA [16]	0,839	0,876
	NCMQE [15]	0,879	0,889
	LGF-CMVQA [7]	<b>0,899</b>	<b>0,901</b>
Proposées	Brisque-R-V	0,515	0,603
	Brisque-R-P	<b>0,605</b>	0,598
	Brisque-R-VP	0,579	<b>0,613</b>
	CMDQA-BM-A-V	0,953	0,962
	CMDQA-BM-A-P	0,872	0,925
	CMDQA-BM-R-V	0,963	0,965
	CMDQA-BM-R-P	0,821	0,897
	CMDQA-BM-R-VP	0,774	0,848
	CMDQA-BM-R-VPB	<b>0,979</b>	<b>0,970</b>

TABLE 1 : Comparaison des valeurs SROOC et PLCC des méthodes proposées avec les approches de l'état de l'art.

### 3.4 Résultats et évaluations

Dans cette section, nous comparons l'approche proposée prenant en compte les caractéristiques géométriques et colorimétriques profondes (extraites avec VGG16) ainsi que les caractéristiques du domaine spatial à partir des projections de maillage (calculées avec BRISQUE). Pour comparer les performances de notre métrique proposée par rapport aux métriques existantes sans référence (NR) et avec référence complète (FR), nous comparons les coefficients de corrélation SROCC et PLCC sur la base de données CMDM. Avec le protocole d'entraînement LOMO-CV, nous obtenons des scores par maillage qui peuvent être soit moyennés, soit calculés pour l'ensemble des maillages. Nous considérons les deux scores à des fins de comparaison, comme cela est également fait dans l'état de l'art.

Pour faciliter la lecture du tableau (Table 1), nous avons introduit les conventions suivantes : les meilleurs taux sont **mis en gras** dans chaque colonne pour chaque catégorie d'approche, la meilleure approche de l'état de l'art est affichée avec la couleur ■, le meilleur protocole BRISQUE est représenté en ■, et notre meilleur modèle est indiqué en ■.

Une comparaison entre les métriques sans référence de l'état de l'art et nos métriques est réalisée pour évaluer leurs performances sur la base CMDM. Parmi les meilleures, NCMQE et LGF-CMVQA montrent des corrélations élevées avec la perception humaine. NCMQE, entraînée sur des maillages colorés, surpasse 3D-NSS, conçu pour des nuages de points. Certaines métriques comme NR-SVR, NR-CNN et BRISQUE montrent des corrélations modérées. Nos méthodes proposent une combinaison des scores BRISQUE de vues et de patches pour améliorer la performance. CMDQA-BM obtient des scores compétitifs, dépassant parfois les meilleures métriques de l'état de l'art. L'intégration des scores de vues et de patches renforce la précision des évaluations. Cependant, les résultats détaillés de certaines métriques NR sur CMDM ne sont pas disponibles. Nos méthodes sont aussi comparées à des mé-

triques FR, incluant celles de Nehmé et des métriques destinées à l'évaluation avec référence de la qualité des images 2D. CMDQA-BM-R-VPB obtient la meilleure performance parmi toutes les méthodes évaluées.

## 4 Conclusion

Dans cette étude, nous avons proposé une nouvelle approche pour évaluer la qualité visuelle des maillages 3D colorés sans référence, comblant ainsi une des lacunes de la littérature. Notre méthode, CMDQA, exploite des caractéristiques profondes extraites des projections 2D des maillages et de leurs patches, combinées à l'indice de qualité d'image sans référence BRISQUE. Nous avons démontré l'efficacité de notre approche pour prédire la qualité globale et sa supériorité par rapport aux métriques existantes de l'état de l'art.

## Références

- [1] Ilyass ABOUELAZIZ, Aladine CHETOUANI, Mohammed El HASSOUNI, Hocine CHERIFI et Longin Jan LATECKI : Learning graph convolutional network for blind mesh visual quality assessment. *IEEE Access*, 9: 108200–108211, 2021.
- [2] Ilyass ABOUELAZIZ, Aladine CHETOUANI, Mohammed El HASSOUNI, Longin Jan LATECKI et Hocine CHERIFI : 3d visual saliency and convolutional neural network for blind mesh quality assessment. *Neural Comput. Appl.*, 32(21):16589–16603, 2020.
- [3] Ilyass ABOUELAZIZ, Aladine CHETOUANI, Mohammed El HASSOUNI, Longin Jan LATECKI et Hocine CHERIFI : No-reference mesh visual quality assessment via ensemble of convolutional neural networks and compact multi-linear pooling. *Pattern Recognit.*, 100:107174, 2020.
- [4] Ilyass ABOUELAZIZ, Mohammed El HASSIMOSOUNI et Hocine CHERIFI : No-reference 3d mesh quality assessment based on dihedral angles model and support vector regression. In *ICISP*, volume LNCS 9680, pages 369–377, 2016.
- [5] Ilyass ABOUELAZIZ, Mohammed El HASSOUNI et Hocine CHERIFI : A curvature based method for blind mesh visual quality assessment using a general regression neural network. In *SITIS*, pages 793–797, 2016.
- [6] Ilyass ABOUELAZIZ, Mohammed El HASSOUNI et Hocine CHERIFI : A convolutional neural network framework for blind mesh visual quality assessment. In *ICIP*, pages 755–759, 2017.
- [7] Mohammed El HASSOUNI et Hocine CHERIFI : Learning graph features for colored mesh visual quality assessment. In *IEEE International Conference on Image Processing, ICIP*, pages 3381–3385, 2022.
- [8] Z. IBORK, A. NOURI, O. LÉZORAY, C. CHARRIER et R. TOUAHNI : No reference 3d mesh quality assessment using deep convolutional features. In *International Symposium on Image and Signal Processing and Analysis (ISPA - IEEE)*, pages 1–6, 2023.
- [9] Anish MITTAL, Anush Krishna MOORTHY et Alan Conrad BOVIK : No-reference image quality assessment in the spatial domain. *IEEE Trans. Image Process.*, 21(12):4695–4708, 2012.
- [10] Anish MITTAL, Rajiv SOUNDARARAJAN et Alan C. BOVIK : Making a "completely-blind" image quality analyzer. *IEEE Signal Process. Lett.*, 20(3):209–212, 2013.
- [11] Yana NEHMÉ, Florent DUPONT, Jean-Philippe FARRUGIA, Patrick Le CALLET et Guillaume LAVOUÉ : Visual quality of 3d meshes with diffuse colors in virtual reality : Subjective and objective evaluation. *IEEE Trans. Vis. Comput. Graph.*, 27(3):2202–2219, 2021.
- [12] Anass NOURI, Christophe CHARRIER et Olivier LÉZORAY : 3d blind mesh quality assessment index. In *3DIPM*, pages 9–16, 2017.
- [13] Karen SIMONYAN et Andrew ZISSERMAN : Very deep convolutional networks for large-scale image recognition. In *ICLR*, 2015.
- [14] Zicheng ZHANG, Wei SUN, Xiongkuo MIN, Tao WANG, Wei LU et Guangtao ZHAI : No-reference quality assessment for 3d colored point cloud and mesh models. *IEEE Trans. Circuits Syst. Video Technol.*, 32(11):7618–7631, 2022.
- [15] Zicheng ZHANG, Wei SUN, Xiongkuo MIN, Tao WANG, Wei LU, Wenhan ZHU et Guangtao ZHAI : A no-reference visual quality metric for 3d color meshes. In *IEEE International Conference on Multimedia & Expo Workshops*, pages 1–6, 2021.
- [16] Zicheng ZHANG, Wei SUN, Houning WU, Yingjie ZHOU, Chunyi LI, Xiongkuo MIN, Guangtao ZHAI et Weisi LIN : GMS-3DQA : projection-based grid mini-patch sampling for 3d model quality assessment. *CoRR*, abs/2306.05658, 2023.