

適応型点群映像ストリーミングにおけるユーザ体験品質（QoE）のモデリング

研究代表者
共同研究者

グエンヴァンドウック
チョントゥフォン

東北工業大学情報通信工学科・講師
ハノイ工科大学電気電子工学部・准教授

1 初めに

点群映像（Point Cloud Video）は、三次元空間内の点の集合によって 3D オブジェクトを表現する映像形式であり、仮想現実（VR）および拡張現実（AR）アプリケーションにおいて重要なコンテンツである[1]。6 自由度（6DoF）を提供することにより、点群映像は従来の映像や 360 度映像よりもはるかに高い没入感を実現する。しかしながら、実際の 3D オブジェクトを忠実に再現するためには大量のデータが必要となるため、点群映像は非常に高いデータレートを持つ。例えば、1 秒あたり 30 フレームで約 100 万点を含む単一オブジェクトの点群映像は、非圧縮状態で最大 6Gbps にも達する[2]。このため、ネットワーク上での点群映像ストリーミングは非常に困難な課題である。




図 1. 点群映像伝送システムの概要図

この課題に対処するため、適応型点群映像ストリーミング手法が提案されている[3][4][5]。その基本的な枠組みでは、元の点群映像を時間方向に複数のチャンクに分割し、各チャンクを MPEG-PCC [3]などの符号化技術を用いて異なる品質レベルの複数バージョンにエンコードする。次に、ネットワーク状態やユーザの要件に応じて、各チャンクについて最適な品質のバージョンを選択し、ユーザ端末へ送信することで、復号および表示が行われる（図 1）。しかし、無線ネットワークのように通信状態が不安定な環境では、この適応型ストリーミングはユーザの視聴体験に悪影響を与える可能性がある。特に、利用可能帯域などのネットワーク条件に基づいてチャンクごとに異なる品質が選択されるため、チャンク間で品質が異なる現象、いわゆる時間的画質変動（temporal quality variation）が発生する。また、帯域が急激に低下した場合には伝送遅延が増大し、端末側での再生が一時的に停止するストーリング（stalling）が発生する可能性がある。

これらの要因がユーザの QoE（体験品質）に与える影響を理解し、モデル化することは、実用的な点群映像ストリーミングシステムの設計および最適化において極めて重要である。しかしながら、既存研究では点群映像におけるユーザ知覚への影響は十分に検討されていない。文献[6]では時間的画質変動が QoE に与える影響が初めて調査されているが、単一の品質切替のみを考慮した単純なパターンに限られている。文献[7]では 16 種類の品質変動パターンに対する主観評価が行われているものの、実験環境はデスクトップ PC 上であり、点群映像が主に VR ヘッドセットや MR デバイスで利用されるという実運用環境とは異なる。一方で、ストーリングが点群映像の QoE に与える影響についてはこれまで検討されておらず、さらに適応型点群映像ストリーミングにおける効果的な QoE 予測モデルも十分に提案されていない。

このような研究のギャップを解消するため、本論文では VR 環境における適応型点群映像ストリーミングにおいて、時間的画質変動およびストーリングがユーザ QoE に与える影響を評価し、そのモデル化を行うことを目的とする。具体的には、VR 環境で主観評価実験を実施し、大規模な QoE データベースを構築すると

もに、ビットストリーム情報に基づく新しい QoE 予測フレームワークを提案する。本研究の主な貢献は以下の通りである。第一に、適応型点群映像ストリーミングにおける大規模 QoE データベースを構築し、4 種類の元映像から生成された時間的画質変動およびストーリーリングを含む 248 のテスト系列に対するユーザ評価を収録している。第二に、時間的画質変動およびストーリーリングの影響を考慮した QoE 予測のための新しいフレームワークを提案し、提案モデルが PLCC, SROCC, RMSE の観点から高い予測性能を示すことを明らかにした。

2 関連研究

2-1 点群ビデオストリーミング

点群映像を効率的にネットワーク上で配信するために、適応型点群映像ストリーミング手法が提案されている。文献[5]では、ビットレート適応ストリーミングの概念を拡張し、DASH-PC が提案されている。この手法は視点に応じた帯域効率の高い点群ストリーミング方式であり、空間サブサンプリングを用いて複数の品質レベルの点群データを生成する。適切な品質バージョンの選択は、利用可能なネットワーク帯域とユーザの嗜好に基づいて行われる。

また、文献[3]および[4]では、複数の点群映像に対応した適応型ストリーミングフレームワークが提案されており、MPEG V-PCC 圧縮規格を用いて複数の品質バージョンを生成している。さらに、ネットワーク帯域の削減を目的として、タイルベースの適応型ストリーミング手法も提案されている[8]-[10]。視点適応型点群映像ストリーミングでは、点群データを空間的および時間的に 3 次元タイルへ分割し、各タイルを複数の品質レベルで符号化する。そして、ネットワーク帯域およびユーザの視点に基づいて、適切なタイルの品質バージョンが選択される。

2-2 点群ビデオの品質評価

これまでの研究において、点群映像の主観的品質評価は、さまざまな実験条件、評価手法、表示デバイス、および品質劣化要因のもとで実施されてきた。しかし、多くの先行研究は、主に符号化処理によって生じる品質劣化に焦点を当てている[11][12]。さらに、視聴距離[6][11][13]、フレームレート[11]、および映像符号化方式[11]といった他の要因が知覚品質に与える影響についても検討されている。

しかしながら、適応型点群映像ストリーミングがユーザ QoE に与える影響については、十分に検討されていない。これまでにいくつかの研究が QoE に関する検討を行っているものの、まだ限定的である。文献[14]では、利用可能帯域、レート割り当て戦略、視点予測手法、およびユーザ動作が QoE に与える影響が分析されているが、時間的画質変動およびストーリーリングは考慮されていない。

文献[6]では、Mixed Reality 環境において点群映像の時間的画質変動がユーザ知覚に与える影響が初めて調査されており、低品質への切り替えが QoE を低下させることが示されている。しかし、この研究では単一の品質切替のみを含む単純なパターンしか扱っていない。文献[7]では、16 種類の時間的画質変動パターンが QoE に与える影響が主観評価により検証されているが、評価は 2 次元ディスプレイ上で実施されており、点群映像の主な視聴環境である VR/AR デバイスとは異なる。

したがって、仮想現実環境における適応型点群映像ストリーミングの QoE 評価およびモデリングには、依然として大きな研究ギャップが存在する。特に、ストーリーリングが QoE に与える影響については、これまでの研究において全く検討されていない。

3 データベースの構築




図 2：点群映像のスナップショット

本節では、テストサンプルの生成方法、評価環境、および評価手順について述べ、その後に主観評価結果の統計分析を行う。

3-1 テストサンプルの作成

主観評価実験では、8i Voxelized Full Body Dataset に含まれる点群映像 (Longdress, Loot, RedandBlack, Soldier) の4種類を使用する。図2は本研究で用いた点群映像のスナップショットを示す。各映像は10秒間の長さを有し、人間の全身動作を収録している。

Quality	GQP	TQP	Loot	RedandBlack	Soldier	Longdress
R1	32	42	2.27	3.38	4.37	4.64
R2	28	37	3.48	4.88	6.96	7.97
R3	24	32	5.62	7.55	11.58	14.05
R4	20	27	9.41	12.76	19.95	25.97
R5	16	22	16.67	22.91	35.29	46.77

表1: 各品質レベルにおけるQP値とチャンクの平均ビットレート

テストサンプルを生成するため、各点群映像を2秒ごとに5つのチャンクに分割し、それぞれのチャンクをMPEG V-PCC圧縮規格[1]を用いて5つの品質レベルにエンコードする。各品質レベルは、幾何量子化パラメータ (Geometry QP) およびテクスチャ量子化パラメータ (Texture QP) によって制御される。表1に、各品質レベルにおけるQP値とチャンクの平均ビットレートを示す。本研究では、時間的画質変動またはストーリーリングを含むテストサンプルを以下のように生成する。

1) 時間的画質変動を含むテストサンプル

各点群映像について、あらかじめ定義したパターンに基づきチャンクを連結することにより、29種類の時間的画質変動パターンを生成する。主なパターンは以下の通りである。

- Constant (5パターン): 全てのチャンクが同一品質 (R1~R5)
- Spike (4パターン): R5-Rx-R5-Rx-R5のパターンで、奇数チャンクは最高品質 (R5)、偶数チャンクは低品質 (R1~R4)
- Inverse Spike (4パターン): Rx-R5-Rx-R5-Rxのパターン
- Single Drop (12パターン): 初期品質 R5 から低品質 Rx へ低下し、再び R5 へ戻るパターン (低品質継続時間は1~3チャンク)
- Single Increase (4パターン): 低品質から一時的に R5 へ上昇し、再び元の品質に戻るパターン

2) ストーリングを含むテストサンプル

ストーリングに関する評価では、各点群映像について33種類のテストサンプルを生成する。全てのチャンクは最高品質 R5 とし、チャンクの末尾にストーリングを挿入する。ストーリング時間は0.25秒から4秒までの8種類を設定する。

- Single-Stall (16パターン): 1回の停止 (第1または第4チャンク後)
- Double-Stall (8パターン): 2回の停止 (第1・第3または第2・第3チャンク後)
- Triple-Stall (6パターン): 3回の停止 (指定チャンク位置)
- Quadruple-Stall (3パターン): 最終チャンク以外の全チャンク後に停止


以上により、4種類の点群映像から合計248種類のテストサンプルを生成する。時間的画質変動のみのテストサンプルは10秒長であり、ストーリングを含むテストサンプルは10秒に総停止時間を加えた長さとなる。

3-2 評価環境および評価手順


本研究では、32GB以上のメモリを必要とする従来環境[15]に対して、点群をリアルタイムで読み込み・描画する環境を開発し、メモリ使用量を削減した。Miniplyを用いてPLY形式の点群データを読み込み、30fpsでリアルタイム表示を実現する。さらに、UnityのSingle-Pass Instancedレンダリングを用いたポイントシェーダを実装し、CPUおよびGPU負荷を軽減した。評価には、Intel Core i5-10400 (CPU)、16GBメモリ、NVIDIA GeForce RTX2060 (GPU) を搭載したワークステーションと、HTC Vive Proを用いた。仮想環境内で

は点群映像を高さ約 1.8m にスケーリングし、被験者はコントローラを用いて再生開始および品質評価を行う。評価前にはトレーニングを実施し、機器の装着方法や操作方法を説明する。評価手法として単一テストサンプル法を採用し、各テストサンプルを独立に提示し、以下の 5 段階で評価する：5 (Excellent), 4 (Good), 3 (Fair), 2 (Poor), 1 (Bad)。被験者は 19 歳から 45 歳の 43 名であり、全員が正常または矯正視力を有する。評価時間は約 40 分であり、各テストサンプルは少なくとも 17 名以上により評価される。取得した評価データは異常値除去を行った後、各テストサンプルの平均意見スコア (MOS) として算出する。

3-3 統計分析結果



(a) 時間的画質変動のサンプル (b) ストージングのサンプル
図 3：平均意見スコア (MOS) の累積分布関数



(a) 時間的画質変動のサンプル (b) ストージングのサンプル
図 4：平均意見スコア (MOS) の平均と分散

主観評価結果に対して統計分析を実施する。図 3 に時間的画質変動およびストージングを含むテストサンプルの累積分布関数 (CDF) を示す。結果より、評価スコアは 1 から 5 の範囲でほぼ正規分布しており、提案データセットが「低品質から高品質まで幅広い視聴体験」を適切に包含していることが確認される。図 4 に各点群映像の評価スコアの図を示す。結果から、時間的画質変動およびストージングの影響はコンテンツ依存であることが分かる。例えば、Loot 映像は画質変動に対して最も高い平均評価を示す一方、ストージングが発生した場合には最も低い評価となる。

4 ユーザ体験品質モデル

本節では、時間的画質変動およびストージングがユーザの体験品質 (QoE) に与える影響を定量化するための、2 つの新しい QoE 予測モデルについて述べる。

4-1 時間的画質変動

提案 QoE モデルは、時間的画質変動が与える影響を考慮して、点群映像に対するユーザの QoE を予測するために用いられるものである。提案モデルでは、以下の情報を入力として利用する。すなわち、各チャンク

における幾何量子化パラメータ (Geometry QP), テクスチャ量子化パラメータ (Texture QP), およびビットレートである。

幾何 QP および テクスチャ QP の情報は符号化ビットストリーム内に記録されているため, 元の非圧縮データにアクセスすることなく, エンコードされた点群映像のビットストリームから直接抽出することが可能である。また, チャンクのビットレートは, チャンクのデータサイズをその再生時間で除算することによって算出される。

幾何量子化パラメータを GQP_i 、テクスチャ量子化パラメータを TQP_i ビットレートをとし、それぞれチャンク $i (1 \leq i \leq N)$ に対して選択された品質レベルに対応する値を表すものとする。チャンクの品質レベルを表現するために、本研究では幾何 QP とテクスチャ QP の合計値を用いる。さらに、以下の 6 つの特徴量を定義する。すなわち、平均値 (x_1^{qp})、標準偏差 (x_2^{qp})、最小値 (x_3^{qp})、最大値 (x_4^{qp})、品質低下 (ダウンスイッチ) の回数 (x_5^{qp})、および品質向上 (アップスイッチ) の回数 (x_6^{qp}) であり、これらは次式により算出される。

$$x_1^{qp} = \frac{1}{N} \sum_{i=1}^N (GQP_i + TQP_i) \quad (1a)$$

$$x_2^{qp} = \sqrt{\frac{1}{N} \sum_{i=1}^N (GQP_i + TQP_i - x_1^{qp})^2} \quad (1b)$$

$$x_3^{qp} = \min(GQP_i + TQP_i, 1 \leq i \leq N) \quad (1c)$$

$$x_4^{qp} = \max(GQP_i + TQP_i, 1 \leq i \leq N) \quad (1d)$$

$$x_5^{qp} = \sum_{i=1}^{N-1} \mathbf{1}(GQP_{i+1} + TQP_{i+1} - GQP_i - TQP_i) \quad (1e)$$

$$x_6^{qp} = \sum_{i=1}^{N-1} \mathbf{1}(GQP_i + TQP_i - GQP_{i+1} - TQP_{i+1}) \quad (1f)$$

式 (1e), (1f) において、関数 $\mathbf{1}(\cdot)$ は、引数が正のときに 1 を返し、それ以外の場合には 0 を返す関数である。各チャンクのビットレートが与えられると、平均値 (x_1^{br})、標準偏差 (x_2^{br})、最小値 (x_3^{br})、最大値 (x_4^{br}) の 4 つの特徴量が算出される。

$$x_1^{br} = \frac{1}{N} \sum_{i=1}^N r_i \quad (2a)$$

$$x_2^{br} = \sqrt{\frac{1}{N} \sum_{i=1}^N (r_i - x_1^{br})^2} \quad (2b)$$

$$x_3^{br} = \min(r_i, 1 \leq i \leq N) \quad (2c)$$

$$x_4^{br} = \max(r_i, 1 \leq i \leq N) \quad (2d)$$

ユーザの QoE は、これらの特徴量の重み付き和として次式により予測される。

$$QoE^{Pred} = \sum_{j=1}^6 w_j^{qp} \times x_j^{qp} + \sum_{j=1}^4 w_j^{br} \times x_j^{br} \quad (3)$$

式 (3) において、モデルパラメータ $\{w_j^{qp}, 1 \leq j \leq 6\}$, $\{w_j^{br}, 1 \leq j \leq 4\}$ は、各特徴量が QoE 全体に与える寄与を表す。これらのパラメータ値は、最小二乗法[17]を用いて学習される。また、過学習を防ぐために、損失関数として L2 正則化を伴う平均二乗誤差が用いられる。

$$L^1 = \frac{1}{N_s} \sum_{i=1}^{N_s} (QoE_i^{Pred} - QoE_i)^2 + \alpha \left(\sum_{j=1}^6 (w_j^{qp})^2 + \sum_{j=1}^4 (w_j^{br})^2 \right) \quad (4)$$

ここで、 QoE_i^{Pred} および QoE_i はそれぞれテストサンプル*i*に対する予測 QoE と実測 QoE を表し、 N_s はサンプル数を表す。損失関数の第一項は平均二乗誤差を表し、第二項は L2 正則化項である。なお、 α は正則化の強さを制御するハイパーパラメータであり、本研究では $\alpha = 1.0$ に設定されている。

4-2 ストリーミング影響のモデリング

ストリーミングがユーザ QoE に与える影響を定量化するため、本研究では新たな QoE 予測モデルを提案する。このモデルは、弱学習器（決定木）のアンサンブルを用いて予測を行う勾配ブースティング法[18]に基づいている。各チャックにおけるストリーミング時間 $\{s_i, 1 \leq i \leq N-1\}$ が与えられると、総停止時間 (x_1^s)、ストリーミング回数 (x_2^s)、最小停止時間 (x_3^s)、最大停止時間 (x_4^s)、およびストリーミングマスク (x_5^s) の5つの特徴量が算出される。

$$x_1^s = \sum_{i=1}^N s_i \quad (5a)$$

$$x_2^s = \sum_{i=1}^N \mathbf{1}(s_i) \quad (5b)$$

$$x_3^s = \min(s_i \mid s_i > 0, 1 \leq i \leq N) \quad (5c)$$

$$x_4^s = \max(s_i, 1 \leq i \leq N) \quad (5d)$$

$$x_5^s = \sum_{i=1}^N \mathbf{1}(s_i) \times 2^{i-1} \quad (5e)$$

式(5e)で定義されるストリーミングマスクは、各チャックの停止時間を二値列に変換することで算出される。具体的には、停止時間が 0 でない場合を 1、それ以外を 0 とする二値列に変換し、これを 10 進数に変換する。この特徴量により、停止回数および停止時間が同一であっても、停止位置が異なるサンプルを識別することが可能となる。

入力特徴ベクトルを x とすると、提案する QoE モデル $F(x)$ は、以下のように M 個の基学習器 $h_m(x)$ の重み付き和として表現される。

$$F(x) = \sum_{i=1}^M \gamma_m h_m(x) + \gamma_0 \quad (6)$$

係数 γ_m と基学習器 $h_m(x)$ はモデルパラメータであり、反復的に学習される。ここで、 x_i を入力特徴ベクトル、 y_i をサンプル i の QoE スコアとする。まずモデルは定数値 $F_0(x)$ によって初期化される。その後、 $m = 1$ から M に対して以下の手順を繰り返すことでモデルを更新する。

- 1) 現在のモデル $F_{m-1}(x)$ に基づき、損失関数の負の勾配 $\{r_{im}\}_{i=1}^{N_s}$ を計算する。
- 2) 学習データ $\{(x_i, r_{im})\}_{i=1}^{N_s}$ を用いて基学習器 $h_m(s)$ を学習する。
- 3) 係数 γ_m を以下の最適化問題により求める。

$$\gamma_m = \operatorname{argmin} \sum_{i=1}^{N_s} L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i))$$

- 4) モデルを以下のように更新する。

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x)$$

最終反復で得られるモデル $F_M(x)$ が QoE 予測値を出力する、すなわち $QoE^{Pred} = F_M(x)$ である。本研究では損失関数として平均二乗誤差を用いる。また、入力特徴ベクトル x はすべてのストリーミング関連特徴量および平均ビットレートを含む $x = (x_1^s, x_2^s, x_3^s, x_4^s, x_5^s, x_1^{br})$ 。反復回数 M は 100 と設定されている。

4-2 性能評価

Point Cloud Video	QoE Model #1 (Temporal Quality Variation)						QoE Model #2 (Stalling)					
	Training Set			Test Set			Training Set			Test Set		
	PLCC	SROCC	RMSE	PLCC	SROCC	RMSE	PLCC	SROCC	RMSE	PLCC	SROCC	RMSE
Longdress	0.98	0.98	0.24	0.97	0.97	0.26	0.99	0.99	0.09	0.95	0.94	0.24
Loot	0.97	0.94	0.25	0.97	0.92	0.25	0.99	0.99	0.08	0.95	0.93	0.22
RedandBlack	0.98	0.98	0.20	0.97	0.97	0.25	0.99	0.98	0.11	0.95	0.95	0.26
Solider	0.98	0.97	0.30	0.97	0.96	0.32	0.97	0.96	0.16	0.93	0.88	0.31
All	0.97	0.96	0.25	0.96	0.94	0.27	0.99	0.99	0.11	0.94	0.94	0.26

表 2：提案 QoE モデルの PLCC、SROCC、RMSE

提案手法の性能評価のため、構築した QoE データベースをランダムに分割し、80%を学習データ、残りをテストデータとして利用する。モデルは学習データで訓練し、テストデータで評価を行う。この分割と評価を 10 回繰り返すことで、結果の偏りを低減する。性能評価には、Pearson 相関係数 (PLCC)、Spearman 順位相関係数 (SROCC)、および平均二乗誤差 (RMSE) を用いる。表 II に示す結果より、提案モデルは各点群映像および全映像において高い予測性能を達成している。QoE モデル#1 では、PLCC が 0.96 以上、SROCC が 0.92 以上、RMSE が 0.32 以下である。また、QoE モデル#2 では、PLCC が 0.93 以上、RMSE が 0.31 以下となっている。これらの結果は、提案モデルが時間的画質変動およびストーリーリングの影響を考慮した場合でも、主観 QoE スコアを高精度に予測可能であることを示している。

5 結論と今後の展望

本研究では、適応型点群映像ストリーミングにおける QoE に関する大規模主観評価実験を実施し、時間的画質変動およびストーリーリングの影響を含む QoE データベースを構築した。このデータベースは 4 種類の点群映像から生成された 248 のテスト系列に対するユーザ評価を含む。また、ビットストリーム情報に基づく参照不要型 QoE 予測フレームワークを提案し、2 種類の有効な QoE モデルを構築した。

今後の課題として、初期遅延、空間的画質変動、ユーザ嗜好などの追加要因の検討、および異なるプラットフォームや利用環境間における QoE の比較評価を行う予定である。

【参考文献】

- [1] S. Schwarz *et al.*, “Emerging MPEG standards for point cloud compression,” *IEEE J. Emerg. Sel. Topics Circuits Syst.*, vol. 9, no. 1, pp.133–148, 2018.
- [2] E. d'Eon, B. Harrison, T. Myers, and P. A. Chou, “8i voxelized full bodies—a voxelized point cloud dataset, iso/iec jtc1/sc29 joint wg11/wg1 (mpeg/jpeg) input document wg11m40059/wg1m74006,” *Geneva*, 2017.
- [3] J. Van Der Hooft, T. Wauters, F. De Turck, C. Timmerer, and H. Hellwagner, “Towards 6dof http adaptive streaming through point cloud compression,” in *Proc. 27th ACM International Conference on Multimedia*, Nice, France, Oct. 2019, pp. 2405–2413.
- [4] Q. L. Nguyen, D. Nguyen, and H. T. Truong, “Toward optimal real-time dynamic point cloud streaming over bandwidth-constrained networks,” in *Proc. 5th ACM International Conference on Multimedia in Asia*, Tainan, Taiwan, Dec. 2023, pp. 1–7.
- [5] M. Hosseini and C. Timmerer, “Dynamic adaptive point cloud streaming,” in *Proc. 23rd Packet Video Workshop*, Amsterdam, Netherlands, 2018, p. 25–30.
- [6] M. Nguyen *et al.*, “Impact of quality and distance on the perception of point clouds in mixed reality,” in *Proc. 15th International Conference on Quality of Multimedia Experience*, Ghent, Belgium, Jun. 2023, pp.87–90.
- [7] S. R. Cox, M. Lim, and W. T. Ooi, “Volvqad: An mpeg v-pcc volumetric video quality assessment dataset,” in *Proc. 14th Conf. on ACM Multimedia Systems*, Vancouver, BC, Canada, 2023, p. 357–362.
- [8] J. Park, P. A. Chou, and J.-N. Hwang, “Rate-utility optimized streaming of volumetric media for augmented reality,” *IEEE J. Emerg. Sel. Topics Circuits Syst.*, vol. 9, no. 1, pp. 149–162, 2019.

- [9] X. Wang, W. Liu, H. Liu, and P. Yang, “Spatial perceptual quality aware adaptive volumetric video streaming,” in *Proc. IEEE GLOBECOM 2023*, Kulalumpur, Malaysia, Dec. 2023, pp. 1000–1005.
- [10] J. Li *et al.*, “Towards optimal real-time volumetric video streaming: A rolling optimization and deep reinforcement learning based approach,” *IEEE Trans. Circuits Syst. Video Technol.*, vol. 33, no. 12, pp. 7870–7883, 2023.
- [11] J. Weil *et al.*, “Modeling quality of experience for compressed point cloud sequences based on a subjective study,” in *Proc. 15th International Conf. on Quality of Multimedia Experience*, Ghent, Belgium, Jun. 2023, pp. 135–140.
- [12] E. Zerman, C. Ozcinar, P. Gao, and A. Smolic, “Textured mesh vs coloured point cloud: A subjective study for volumetric video compression,” in *Proc. Twelfth International Conference on Quality of Multimedia Experience*, Athlone, Ireland, May 2020, pp. 1–6.
- [13] K. Cao, Y. Xu, and P. Cosman, “Visual Quality of Compressed Mesh and Point Cloud Sequences,” *IEEE Access*, vol. 8, pp. 171 203–171 217, 2020.
- [14] J. van der Hooft *et al.*, “Objective and subjective qoe evaluation for adaptive point cloud streaming,” in *Proc. 12th International Conference on Quality of Multimedia Experience*, Athlone, Ireland, May 2020, pp. 1–6.
- [15] S. Vats *et al.*, “A platform for subjective quality assessment in mixed reality environments,” in *Proc. 15th International Conference on Quality of Multimedia Experience*, Ghent, Belgium, Jun. 2023, pp. 131–134.
- [16] I. BT, “Methodologies for the subjective assessment of the quality of television images, document recommendation itu-r bt. 500–14 (10/2019),” *ITU, Geneva, Switzerland*, 2020.
- [17] A. Björck, “Least squares methods,” in *Handbook of numerical analysis*, vol. 1, pp. 465–652, 1990.
- [18] J. H. Friedman, “Greedy function approximation: a gradient boosting machine,” *Annals of statistics*, pp. 1189–1232, 2001.

〈発表資料〉

題 名	掲載誌・学会名等	発表年月
Modeling User Quality of Experience in Adaptive Point Cloud Video Streaming	2024 IEEE Symposium on Multimedia 国際学会	2024 年 12 月 9 日