

# Transformada RAHT com Predição Inter-Quadros para Compressão de Nuvem de Pontos

André L. Souto e Ricardo L. de Queiroz

**Resumo**— Este trabalho estuda o uso da transformada hierárquica adaptativa por região (*region-adaptive hierarchical transform* ou RAHT) juntamente com abordagens preditivas para compressão de atributos de nuvens de pontos dinâmicas. Uma abordagem baseada em predição intra-quadros para a RAHT, onde o resíduo da predição intra-quadros é codificado ao invés dos atributos de cada voxel, já se mostrou capaz de obter ganhos significativos em relação a RAHT convencional. Nós estendemos o esquema para predição inter-quadros e mostramos que uma combinação adaptativa de predições sem vetor de movimento (*zero-motion-vector* ou ZMV) inter-quadros e intra-quadros pode atingir ganhos significativos com relação a RAHT convencional e a RAHT com predição intra-quadros quando utilizada na compressão de atributos de nuvem de pontos dinâmicas. O uso da técnica de baixo custo computacional ZMV serve como uma alternativa aos algoritmos de alto custo computacional para estimação de movimento de nuvem de pontos.

**Palavras-Chave**— RAHT, predição inter-quadros, sem vetor de movimento, nuvens de pontos.

**Abstract**— This work studies the use of region adaptive hierarchical transform (RAHT) with predictive approaches for attribute compression of dynamic point clouds. An intra-frame predictive RAHT, where the intra-frame prediction residuals are encoded instead of the voxel attributes themselves, was shown to deliver large gains over conventional RAHT. We extend the scheme to inter-frame prediction and show that an adaptive combination of zero-motion-vector (ZMV) inter-frame and intra-frame predictions may achieve large gains over conventional RAHT and intra-frame predictive RAHT when compressing attributes of dynamic point clouds. The use of the low computational cost ZMV technique suits as an alternative for high computational cost motion estimation algorithms for point clouds.

**Keywords**— RAHT, inter-frame prediction, zero-motion-vector, point clouds.

## I. INTRODUÇÃO

Nuvens de pontos obtiveram um crescimento em sua popularidade nos últimos anos devido ao aumento de aplicações 3D, como telepresença, realidade virtual e direção autônoma [1]. Nuvens de pontos são definidas como um conjunto de pontos no espaço com geometria e atributos. A geometria consiste em posições 3D ( $x, y, z$ ) de cada ponto da nuvem. Os atributos são geralmente cores (RGB ou YUV), mas refletância, vetores de movimento e outros também podem estar associados a cada ponto da nuvem [2].

Nuvens de pontos podem ser agrupadas em três categorias diferentes: estáticas, dinâmicas e adquiridas dinamicamente

[3]. As estáticas são representadas por um único quadro. As dinâmicas são representadas por múltiplos quadros como uma sequência temporal, exemplificada na Fig. 1. Já as adquiridas dinamicamente pertencem, em geral, a aplicações relacionadas à direção autônoma e são tipicamente obtidas através da tecnologia LiDAR (da sigla inglesa *Light Detection And Ranging*). Este trabalho tem como objetivo melhorar o desempenho da compressão de atributos de nuvens de pontos dinâmicas.

Semelhante a imagens e vídeos, nuvens de pontos representam uma grande quantidade de dados. Dessa forma, é necessário comprimi-las para sua utilização em aplicações práticas [3]–[7]. Por esse motivo, o Grupo de Especialistas de Imagens em Movimento (*Moving Picture Experts Group* ou MPEG) trabalha atualmente com o objetivo de padronizar tecnologias de compressão de nuvem de pontos [3].

A transformada hierárquica adaptativa por região (*region-adaptive hierarchical transform* ou RAHT) [5] foi inicialmente adotada no modelo de testes baseado em geometria do MPEG para compressão de nuvens de pontos (G-PCC) [8]. RAHT foi desenvolvida para codificar sinais de cor e outros atributos, como refletância [5], [9]. Ela consiste em uma transformada hierárquica ortogonal que se assemelha a uma variação adaptativa da transformada Haar. A ideia básica por trás da RAHT é percorrer a *octree* [10] de maneira inversa, dos voxels em direção a nuvem de pontos, em cada etapa, recombinao voxels em outros maiores por meio de uma transformação ao longo de cada direção até a raiz. Cada transformação gera coeficientes passa-baixas e passa-altas. Os coeficientes passa-baixas são transmitidos para o nível superior da *octree* e os coeficientes passa-altas são quantizados e codificados [5].

Na última versão do G-PCC, a transformada RAHT original sofreu modificações. A versão atual consiste em uma implementação de ponto fixo da transformada [11] e uma etapa preditiva intra-quadros foi introduzida resultando em melhoras no desempenho de compressão [12].

Para compressão de nuvem de pontos dinâmicas, estimação de movimento desempenha um papel importante no projeto de algoritmos para predição inter-quadros. Estimação de movimento permite explorar as redundâncias entre diferentes quadros em cenas com quantidades significativas de movimento. Diferentes trabalhos foram realizados com o objetivo de desenvolver um algoritmo robusto para estimação de movimento de nuvens de pontos [6], [7], [13]–[16]. Em [6], [7], [13], [14], abordagens baseadas em grafos e em partições com formato de blocos foram usadas, enquanto outros trabalhos [15], [16] tiveram como objetivo reduzir o custo computacional desses algoritmos. No entanto, algoritmos para estimação de movimento de nuvens de pontos permanecem extremamente custosos computacionalmente e não geram

André L. Souto, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília-DF, e-mail: andre@image.unb.br; Ricardo L. de Queiroz, Departamento de Ciência da Computação, Universidade de Brasília, Brasília-DF, e-mail: queiroz@ieec.org. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e pelo CNPq (301647/2018-6).



Fig. 1. Projeções de múltiplos quadros da nuvem de pontos dinâmica “Soldier”.

previsões de qualidade satisfatória. Este trabalho estuda o uso de abordagens preditivas na transformada RAHT e propõe o uso da técnica de previsão inter-quadros de baixo custo computacional sem vetor de movimento (*zero-motion-vector* ou ZMV) como uma alternativa para melhorar o desempenho da RAHT com previsão intra-quadros na compressão de atributos de nuvens de pontos dinâmicas.

Em nossos testes, na Seção IV, foram usadas duas bases de dados populares de sequências de nuvens de pontos [17], [18]. Foram usados os quadros #594, #124, #16, #18, #1072, #1537, das sequências “Soldier”, “Sarah”, “Ricardo”, “Andrew”, “Loot” e “Redandblack”, respectivamente. Na etapa de previsão inter-quadros, em todos os casos o quadro imediatamente anterior foi usado. Em nossos testes, para avaliação de desempenho são comparadas curvas de taxa-distorção (RD), onde a distorção é medida em PSNR da componente luma (PSNR-Y) e a taxa é medida em bits por voxel ocupado (bpov).

## II. TRANSFORMADA RAHT

A ideia por trás da transformada RAHT é usar os atributos (por exemplo, cores) associados a um nó em um nível mais baixo da *octree* para prever atributos associados a nós no próximo nível [5]. RAHT percorre a estrutura da *octree* de maneira inversa, dos voxels até a nuvem de pontos por completa. Em cada etapa, os nós são combinados ao longo de cada direção  $(x, y, z)$  em nós maiores até a raiz da *octree*. Para um dado nível  $n$ , considere  $g_{n,x,y,z}$  como a cor média do nó na posição  $(x, y, z)$  no espaço.  $g_{n,x,y,z}$  é obtido através da transformação de  $g_{n+1,2x,y,z}$  e  $g_{n+1,2x+1,y,z}$  ao longo da direção  $x$ . Apenas nós ocupados são submetidos à transformada, ou seja, caso um dos nós do par  $g_{n+1,2x,y,z}$  e  $g_{n+1,2x+1,y,z}$  esteja vazio, considere  $g_{n+1,2x+1,y,z}$ , o outro nó é promovido ao próximo nível:  $g_{n,x,y,z} = g_{n+1,2x,y,z}$ . Esse processo é repetido para cada direção e para cada nível até a raiz da *octree*. Cada transformação de pares de nós resulta em coeficientes passa-altas e passa-baixas. Os passa-altas são quantizados e codificados, enquanto os passa-baixas são passados para o próximo nível da *octree*. A transformada RAHT [5] é definida como

$$\begin{bmatrix} g_{n,x,y,z} \\ h_{n,x,y,z} \end{bmatrix} = \frac{1}{\sqrt{p_1 + p_2}} \begin{bmatrix} \sqrt{p_1} & \sqrt{p_2} \\ -\sqrt{p_2} & \sqrt{p_1} \end{bmatrix} \begin{bmatrix} g_{n+1,2x,y,z} \\ g_{n+1,2x+1,y,z} \end{bmatrix} \quad (1)$$

onde  $p_1 = p_{n+1,2x,y,z}$  e  $p_2 = p_{n+1,2x+1,y,z}$  correspondem ao número de voxels, ou pesos, representados por cada um dos nós a serem combinados [5]. De acordo com (1), a matriz da transformada muda constantemente, adaptando-se aos pesos de cada nó [5].

Na última etapa da transformada, na raiz da *octree*, os dois nós restantes representados por  $g_{1,0,0,0}$  e  $g_{1,0,0,1}$  são transformados em dois coeficientes finais:  $g_{0,0,0,0}$  e  $h_{0,0,0,0}$ . O coeficiente passa-baixas da raiz  $g_{0,0,0,0}$  (ou DC) é também codificado juntamente com todos os coeficientes passa-altas gerados durante cada etapa da transformada.

## III. RAHT COM PREDIÇÃO INTRA-QUADROS

A transformada RAHT com previsão intra-quadros consiste na implementação da RAHT descrita na Seção II com uma etapa preditiva intra-quadros aplicada a cada nível da *octree*, no sentido da raiz ao nível de voxels. A previsão intra-quadros introduzida tem como objetivo explorar a correlação espacial entre nós vizinhos.

Considere um nó no nível  $n$  da *octree*, onde seus atributos são representados por  $g_{n,x,y,z}$ . Considere  $g_{n+1,2x,y,z}$  e  $g_{n+1,2x+1,y,z}$  como os atributos de dois sub-nós ocupados (em um total de oito sub-nós) no nível  $n + 1$  e  $\hat{g}_{n+1,2x,y,z}$  e  $\hat{g}_{n+1,2x+1,y,z}$  como sendo as estimativas de  $g_{n+1,2x,y,z}$  e  $g_{n+1,2x+1,y,z}$ , respectivamente. A previsão intra-quadros realiza a superamostragem do nó  $g_{n,x,y,z}$  com seus nós vizinhos para estimar  $\hat{g}_{n+1,2x,y,z}$  e  $\hat{g}_{n+1,2x+1,y,z}$ . O processo de superamostragem consiste na média ponderada de  $g_{n,x,y,z}$  com seus nós vizinhos. Após essa etapa preditiva, tanto os atributos dos sub-nós estimados (i.e.  $\hat{g}_{n+1,2x,y,z}$ ,  $\hat{g}_{n+1,2x+1,y,z}$ ) quanto os originais (i.e.  $g_{n+1,2x,y,z}$ ,  $g_{n+1,2x+1,y,z}$ ) são submetidos à transformada RAHT em (1) gerando, assim, coeficientes estimados e coeficientes originais. As diferenças entre esses coeficientes são calculadas com o objetivo de obter coeficientes residuais, os quais são quantizados e codificados. Esse processo é repetido para todos os nós em cada nível  $n$  da *octree*.

A transformada RAHT com previsão intra-quadros é capaz de obter ganhos significativos com relação a RAHT convencional, como mostrado na Fig. 2 para a nuvem de pontos “Ricardo”.

## IV. RAHT COM PREDIÇÃO INTER-QUADROS

Considere dois quadros subsequentes de uma nuvem de pontos dinâmica, onde  $\Upsilon(t)$  corresponde ao quadro a ser codificado e  $\Upsilon(t - 1)$  corresponde ao quadro imediatamente anterior já localmente decodificado. Um algoritmo de previsão inter-quadros  $E(\cdot)$ , que usa o critério de menor distância Euclidiana entre voxels, é usado para estimar  $\Upsilon(t)$ . Dessa forma,  $\hat{\Upsilon}(t) = E(\Upsilon(t - 1))$  e  $\Lambda(t) = \Upsilon(t) - \hat{\Upsilon}(t) = \Upsilon(t) - E(\Upsilon(t - 1))$ .  $\Lambda(t)$  pode ainda ser submetido a transformada RAHT com previsão intra-quadros (representada aqui por  $I(\cdot)$ ), dessa forma, combinando as abordagens preditivas inter- e intra-quadros:  $I(\Lambda(t))$ . Com o objetivo de garantir a correlação entre atributos para um bom desempenho da previsão intra-quadros, foi decidido calcular as diferenças dos coeficientes ao invés de  $\Lambda(t)$ , isto é, ao invés de  $I(\Lambda(t))$  nós optamos

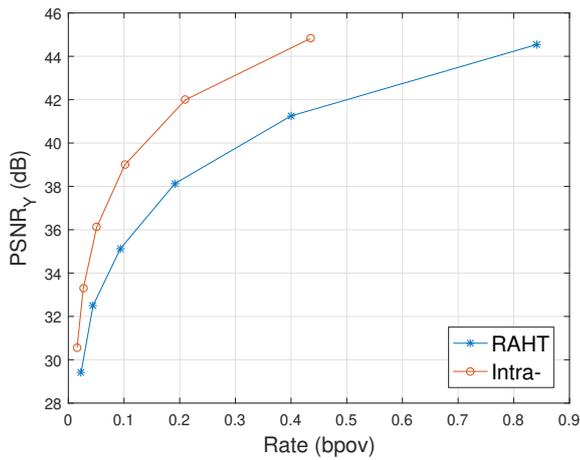


Fig. 2. Desempenho RD da abordagem intra-quadros (Intra-) em relação ao da RAHT convencional para a nuvem de pontos “Ricardo”.

por calcular  $\Theta(t) = \Psi(t) - \hat{\Psi}(t)$ , onde  $\Psi(t) = I(\Upsilon(t))$  e  $\hat{\Psi}(t) = I(\hat{\Upsilon}(t))$ . Assim, ao invés de codificar os coeficientes das diferenças entre os quadros, nós optamos pela diferença entre os coeficientes dos quadros.

O desempenho de compressão da transformada RAHT com predição intra-quadros é ilustrada na Fig. 3 juntamente com o desempenho de compressão da abordagem ZMV de baixo custo computacional para as nuvens de pontos “Soldier”, “Sarah”, “Loot” e “Redandblack”. Note que, na abordagem ZMV,  $\hat{\Upsilon}(t) = \Upsilon(t - 1)$ , i.e.  $E(\cdot)$  é uma identidade e não há estimação ou compensação de movimento. Os pares de quadros das nuvens de pontos “Soldier” e “Sarah”, em particular, apresentam pouco movimento, enquanto os pares de quadros consecutivos das sequências “Loot” e “Redandblack” contêm alto grau de movimento. Dessa forma, espera-se que a predição inter-quadros seja suficientemente acurada para “Soldier” e “Sarah” e insuficiente para “Loot” e “Redandblack”. Essa informação permite inferir que a combinação das abordagens preditivas intra- e inter-quadros deve apresentar ganhos positivos com relação à abordagem intra-quadros para as nuvens de pontos “Soldier” e “Sarah”, mas apresentar uma piora de desempenho de compressão para as nuvens de pontos “Loot” e “Redandblack”. Os resultados ilustrados na Fig. 3 mostram exatamente o que foi inferido. Se não houver muito movimento entre  $\Upsilon(t)$  e  $\Upsilon(t - 1)$ , a correspondência entre nuvens de pontos utilizando apenas a distância entre pontos gera boas predições inter-quadros e ganhos positivos no desempenho. Caso contrário, uma abordagem somente intra-quadros terá um desempenho melhor.

Com o objetivo de melhorar o desempenho de compressão em quadros com muito movimento, uma boa predição inter-quadros tem papel fundamental. Dessa forma, uma solução baseada em estimação de movimento apresenta-se como primeira opção. No entanto, uma solução robusta e confiável baseada em estimação de movimento para quadros de nuvens de pontos permanece um problema ainda não resolvido [6], [13]–[16]. As abordagens atuais para nuvens de pontos são extremamente custosas computacionalmente e não geram uma predição de

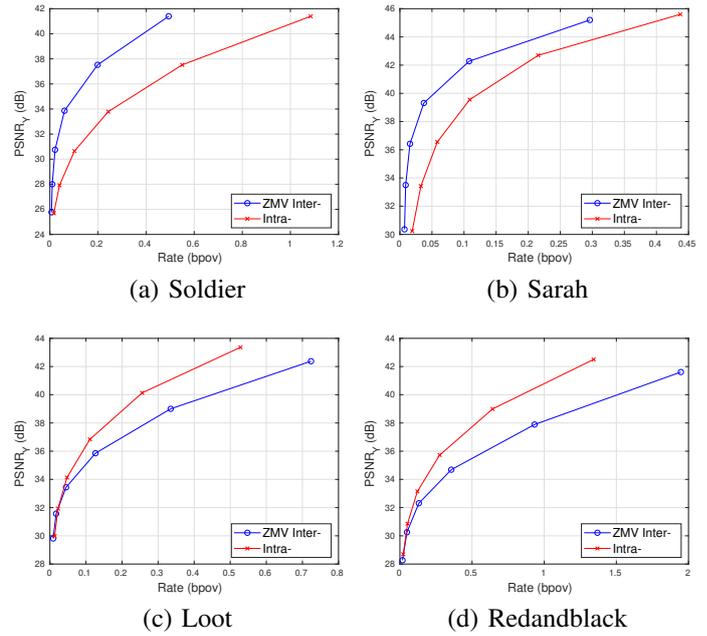


Fig. 3. Desempenho RD da abordagem ZMV inter-intra-quadros (ZMV Inter-) em relação ao da abordagem intra-quadros (Intra-) para as nuvens de pontos “Soldier”, “Sarah”, “Loot” e “Redandblack”.

qualidade satisfatória. Dessa forma, optou-se neste trabalho pelo uso de abordagens ZMV simples como no exemplo acima.

#### A. Abordagem Adaptativa

Com o objetivo de melhorar o desempenho da abordagem ZMV descrita na Seção IV, nós propomos um esquema adaptativo onde a nuvem de pontos é particionada em blocos de dimensões  $16 \times 16 \times 16$  e a predição inter-quadros é usada somente em blocos com pouco movimento.

Considere  $\Upsilon(t)$  como o quadro a ser codificado,  $\Upsilon(t - 1)$  como o quadro imediatamente anterior localmente decodificado,  $\hat{\Upsilon}(t)$  como a estimação de  $\Upsilon(t)$  e  $\Lambda(t) = \Upsilon(t) - \hat{\Upsilon}(t)$ . Inicialmente,  $\Lambda(t)$ ,  $\Upsilon(t)$  e  $\hat{\Upsilon}(t)$  são particionados em blocos  $\{\Lambda_N(t)\}$ ,  $\{\Upsilon_N(t)\}$  e  $\{\hat{\Upsilon}_N(t)\}$  de dimensões  $16 \times 16 \times 16$ , respectivamente. Para cada bloco  $\Lambda_i(t)$  em  $\{\Lambda_N(t)\}$ ,  $\|\Lambda_i(t)\|$  ( $\|\cdot\|$  representa norma  $\mathcal{L}_2$ ) é comparado a um limiar  $\tau$ . Se  $\|\Lambda_i(t)\|$  for menor que  $\tau$ ,  $\hat{\Upsilon}_i(t)$  é considerado confiável,  $\hat{\Upsilon}_i(t)$  e  $\Upsilon_i(t)$  são removidos de  $\hat{\Upsilon}(t)$  e de  $\Upsilon(t)$ , respectivamente. Tais blocos  $\hat{\Upsilon}_i(t)$  considerados confiáveis podem ser obtidos no decodificador através da predição inter-quadros  $E(\cdot)$ . Em seguida,  $\Psi(t)$  e  $\hat{\Psi}(t)$  são obtidos através de  $I(\Upsilon(t))$  e  $I(\hat{\Upsilon}(t))$ , respectivamente. Após isso,  $\|\Lambda(t)\|$  é comparado a um limiar  $\rho$ . Se  $\|\Lambda(t)\|$  for menor que  $\rho$ ,  $\hat{\Upsilon}(t)$  é considerado confiável,  $\Theta(t)$  é calculado a partir de  $\Psi(t)$  e  $\hat{\Psi}(t)$  e codificado. Caso contrário, a estimação  $\hat{\Upsilon}(t)$  é considerada insuficiente e  $\Psi(t)$  é codificado, ao invés de  $\Theta(t)$ . O limiar  $\tau$  foi definido como a distorção (em MSE) de  $\Upsilon(t - 1)$  localmente decodificado e  $\rho = 26$ .

#### B. Resultados Experimentais

Os resultados obtidos para o método ZMV adaptativo são apresentados na Fig. 4 para as nuvens de pontos “Soldier”,

“Sarah”, “Ricardo”, “Andrew”, “Loot” e “Redandblack”. Para as nuvens de pontos “Soldier”, “Sarah”, “Ricardo” e “Andrew” ganhos significativos podem ser observados. Enquanto para as nuvens de pontos “Loot” e “Redandblack”, o desempenho inferior visto na Fig. 3 foi substituído por um desempenho similar ao da abordagem intra-quadros.

Portanto, a abordagem ZMV adaptativa é capaz de atingir ganhos significativos em nuvens de pontos com pouco movimento, garantindo ao mesmo tempo um desempenho similar ao da abordagem com previsão intra-quadros para nuvens de pontos com muito movimento. O algoritmo para previsão inter-quadros utilizado é de baixo custo computacional e serve como uma alternativa ao uso de abordagens de estimação de movimento para nuvens de pontos, atualmente muito custosas computacionalmente e de qualidade insatisfatória.

adaptativo que utiliza uma combinação das técnicas de previsão ZMV inter-quadros e intra-quadros mostrou ganhos significativos com relação à transformada RAHT convencional e à transformada RAHT com previsão intra-quadros. A abordagem proposta apresenta-se como uma alternativa simples e de baixo custo computacional ao uso de algoritmos de estimação e compensação de movimento de nuvem de pontos, os quais são de alto custo computacional.

## REFERÊNCIAS

- [1] C. Tulvan, R. Mekuria, Z. Li, and S. Lasserre, “Use cases for point cloud compression (PCC),” ISO/IEC JTC1/SC29/WG11 MPEG, Tech. Rep. N16331, Jun. 2016.
- [2] S. Schwarz, M. Preda, V. Baroncini, M. Budagavi, P. Cesar, P. A. Chou, R. A. Cohen, M. Krivokuća, S. Lasserre, Z. Li, J. Llach, K. Mammou, R. Mekuria, O. Nakagami, E. Siahhan, A. Tabatabai, A. M. Tourapis, and V. Zakharchenko, “Emerging MPEG standards for point cloud compression,” *IEEE J. Emerging Topics in Circuits and Systems*, vol. 9, no. 1, pp. 133–148, March 2019.
- [3] “Call for proposals for point cloud compression v2,” ISO/IEC JTC1/SC29/WG11 MPEG, output document N16763, April 2017.
- [4] G. Sandri, R. L. de Queiroz, and P. A. Chou, “Compression of plenoptic point clouds,” *IEEE Transactions on Image Processing*, vol. 28, no. 3, pp. 1419–1427, March 2019.
- [5] R. L. de Queiroz and P. A. Chou, “Compression of 3D point clouds using a region-adaptive hierarchical transform,” *IEEE Transactions on Image Processing*, vol. 25, no. 8, pp. 3947–3956, Aug. 2016.
- [6] D. Thanou, P. A. Chou, and P. Frossard, “Graph-based compression of dynamic 3d point cloud sequences,” *IEEE Trans. Image Process.*, vol. 25, no. 4, pp. 1765–1778, April 2016.
- [7] R. Mekuria, K. Blom, and P. Cesar, “Design, implementation, and evaluation of a point cloud codec for tele-immersive video,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 27, no. 4, pp. 828–842, April 2017.
- [8] 3DG, “G-PCC codec description,” ISO/IEC JTC1/SC29/WG11 MPEG, Tech. Rep. W19323, Apr. 2020.
- [9] G. Sandri, R. L. de Queiroz, and P. A. Chou, “Comments on “Compression of 3D Point Clouds Using a Region-Adaptive Hierarchical Transform”,” *ArXiv e-prints*, May 2018.
- [10] D. Meagher, “Geometric modeling using octree-encoding,” *Computer Graphics and Image Processing*, vol. 19, no. 2, pp. 129–147, Jun. 1982.
- [11] G. P. Sandri, P. A. Chou, M. Krivokuća, and R. L. de Queiroz, “Integer alternative for the region-adaptive hierarchical transform,” *IEEE Signal Processing Letters*, vol. 26, no. 9, pp. 1369–1372, Sep. 2019.
- [12] S. Lasserre and D. Flynn, “On an improvement of RAHT to exploit attribute correlation,” ISO/IEC JTC1/SC29/WG11 MPEG, Tech. Rep. M47378, March 2019.
- [13] 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, Aug. 2017.
- [14] —, “Motion-compensated compression of point cloud video,” in *IEEE International Conference on Image Processing (ICIP)*, Sep. 2017, pp. 1417–1421.
- [15] C. Dorea and R. L. de Queiroz, “Block-based motion estimation speedup for dynamic voxelized point clouds,” in *IEEE International Conference on Image Processing (ICIP)*, Oct 2018, pp. 2964–2968.
- [16] C. Dorea, E. M. Hung, and R. L. de Queiroz, “Local texture and geometry descriptors for fast block-based motion estimation of dynamic voxelized point clouds,” in *IEEE International Conference on Image Processing (ICIP)*, Sep. 2019, pp. 3721–3725.
- [17] 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), Tech. Rep. M74006/M40059, Jan. 2017.
- [18] C. Loop, Q. Cai, S. O. Escolano, and P. A. Chou, “Microsoft voxelized upper bodies – a voxelized point cloud dataset,” ISO/IEC JTC1/SC29 & WG11/WG1 (MPEG/JPEG), input document m38673 & M72012, May 2016.

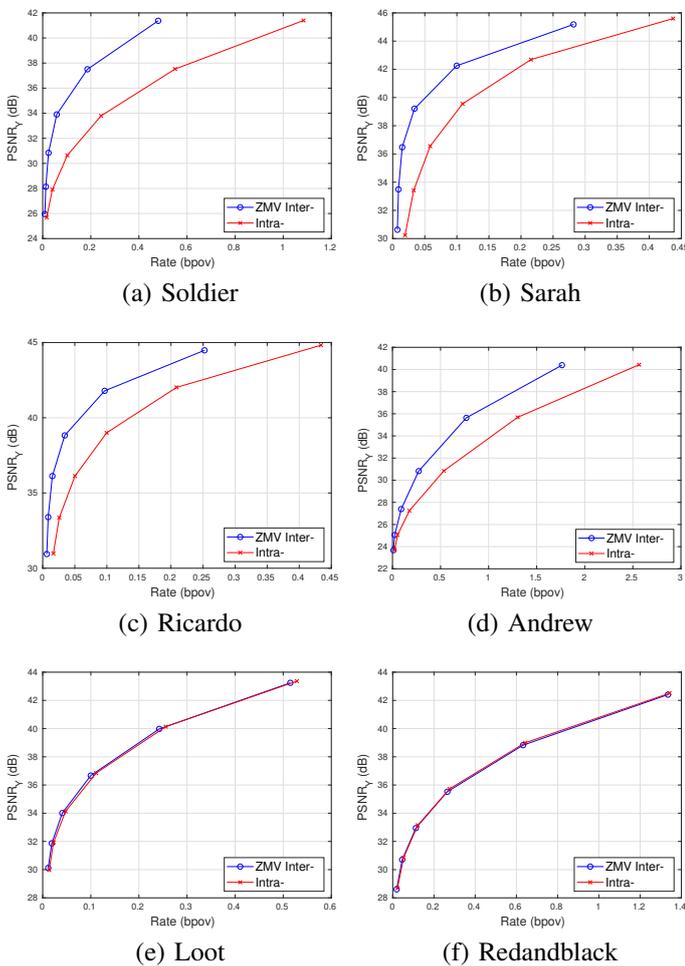


Fig. 4. Desempenho RD da abordagem adaptativa ZMV inter-intra-quadros (ZMV Inter-) em relação ao da abordagem intra-quadros (Intra-) para as nuvens de pontos “Soldier”, “Sarah”, “Ricardo”, “Andrew”, “Loot” e “Redandblack”.

## V. CONCLUSÃO

Este trabalho consiste em um estudo do uso da transformada RAHT juntamente com abordagens preditivas para codificação de atributos de nuvens de pontos dinâmicas. Um esquema