^{7N-04} グラフニューラルネットワークを用いたレートレス点群伝送に関する一検討

 伊吹 将一[†]
 岡本 翼[‡]
 藤橋 卓也[‡]

 † 大阪大学工学部
 ‡ 大阪大学大学院情報科学研究科

1 はじめに

点群は3次元空間上の点を多数用いて3次元情報を表現する.点群 を無線路を介して伝送する場合,伝送中に発生する雑音の影響を低減し つつ,3次元情報をより正確に表現できることが重要となる.本稿では グラフニューラルネットワークを用いた無線点群伝送手法について検討 する.

2 課題

無線伝送路を介してそれぞれのユーザ端末上で3次元情報を正確に 再現しようとする場合,点群無線伝送は以下の3課題を解決する必要が ある.

1つ目は点群伝送に要するデータ量の削減である.点群を無圧縮で伝 送する場合,多大なトラヒックが発生する.点群を圧縮するための符号 化技術として Draco [1], Point Cloud Library (PCL) [2] などが提案 されている.平面上に等間隔でサンプリングされた画素信号を前提とす る画像情報や映像情報の符号化技術とは異なり,点群に対する符号化技 術は 3 次元上で不規則にサンプリングされた信号を対象とする必要があ る.Draco は Kd木, PCL は Octree に挙げられる各点の座標成分を用 いて点群をビット列に圧縮する.また,グラフ信号処理 (Graph Signal Processing: GSP)を用いた符号化手法も提案されている.点群を構成 する各点を頂点,点間の距離を辺の重みとみなした重み付きグラフを符 号化対象とするグラフ信号としてみなすとともに,グラフ信号に対して グラフフーリエ変換 (Graph Fourier Transform: GFT)を用いること で点間に含まれる冗長な情報を削減できることが分かっている.

2 つ目の課題は無線伝送路において生じる雑音に起因する品質低下で ある.前述した既存技術を用いて符号化した点群情報を無線伝送路を介し て送信する場合,伝送路品質,すなわち信号対雑音比 (Signal to Noise Ratio: SNR)が時間的に変動する.伝送路品質が一定値以下になると ビット誤りが発生する.ビット列にはエントロピー復号化に関する情報 が多く含まれているため,少量のビット誤りであってもエントロピー復 号化ができない.結果として,復元される点群の著しい品質劣化を招く ことが分かっている.この著しい品質劣化はクリフ効果と呼ばれている. 一方で,無線伝送路品質が向上した場合であっても、量子化によって欠 落した情報が復元できないため,伝送路品質の向上を点群品質の改善に つなげることができない.伝送路品質の向上と点群品質の改善とが乖離 する現象はレベリング効果と呼ばれている.

3 つ目の課題はそれぞれのユーザによって使用可能な帯域が異なるこ とに起因する品質低下である.前述した既存技術を用いて符号化した点 群情報を複数のユーザに対して同時にマルチキャスト伝送する場合,送 信側は全ユーザの中で最小の帯域幅に合わせて点群情報を符号化する必 要がある.このとき,より広い帯域幅を持つユーザはその差異を点群品 質向上につなげることができない.

本稿では、上述の3課題に対処するために新たな無線点群伝送手法を 提案する.具体的には、グラフニューラルネットワーク (Graph Neural Networks: GNN) に基づいて点群情報を潜在変数に圧縮して無線伝送 路上で伝送するとともに、受信側では得られた潜在変数を点群情報に復 元する.さらに潜在変数空間において、べき乗分布にしたがって潜在変 秋濃 (小池) 俊昭 ^{‡†} 渡辺 尚 [‡]

‡†Mitsubishi Electric Research Laboratories

数をドロップアウトさせ学習することで各ユーザの可用帯域に合わせて 点群品質を向上するレートレス機構を実現する.

3 提案手法

3.1 全体像

図1に提案する点群符号化器・復号化器を含めた全体像を示す.提案 手法はグラフ畳込み層から構成される符号化器,Tail Drop[3],アナロ グ変調および伝送,全結合層から構成される復号化器からなる.符号化 器では3次元点群を重み付き無向グラフ信号 $G = (V, \mathcal{E}, W)$ としてみ なす.ここで $V \in \mathcal{E}$ はそれぞれGの頂点と辺の集合である.また,Wは正の重みをもつ隣接行列,Wの(i, j)番目は頂点 $i \geq j$ の間の辺の 重みを表す.本稿では,頂点数Nの3次元点群 $p = [x, y, z]^T \in \mathbb{R}^{3 \times N}$ をグラフGの頂点集合,4最近傍グラフから得られた隣接行列をグラフ Gの辺集合としてみなす.隣接行列では4最近傍グラフにおいて頂点間 が接続されている辺を1,接続されていない辺を0と定めた.符号化器 を経て得られた潜在変数に対してはべき乗関数にしたがうTail Dropを 学習時に用いることで潜在変数内での優先順位を定め,先頭の潜在変数 からアナログ変調を用いて各ユーザへと伝送する.各ユーザは可用帯域 にしたがって受信した潜在変数を全結合層からなる復号化器に入力して 対応する点群を復元する.

3.2 符号化器

符号化器は符号化関数 f_{θ} を用いて 3 次元点群 pを実数値の潜在変数 $z \in \mathbb{R}^{L \times N}$ に圧縮する. ここで, Lはチャネル数を表す. 符号化関数 f_{θ} は 重み θ のグラフ畳み込みニューラルネットワーク (Graph Convolutional Neural Networks: GCNN) から構成される. 具体的には, グラフ畳み 込み層,活性化関数 Leaky ReLU, 正規化層で構成される. グラフ畳み 込み層ではグラフ信号から特徴量を抽出する. 活性化関数は原信号と潜 在変数との間の対応付けを学習する. 最終層から得られた潜在変数 z は 正規化層を経て平均送信電力 P にしたがって $||z||^2 = mLP$ となるよう 正規化をれる. 符号化器から得られた潜在変数 z は 2 つずつ取り出す ともに, アナログ変調を用いてそれぞれを送信シンボルの同相成分・直交 成分にマッピングして伝送する. 各ユーザは可用帯域に応じて送信シン ボルを一部またはすべて受信する. ここで, y_i は i 番目の受信シンボル, x_i は i 番目のアナログ変調シンボル, $n_i \in \mathbb{C}$ は雑音分散 σ^2 にしたが う加法性白色ガウス雑音 (Additive White Gaussian Noise: AWGN) とすると, i 番目の受信シンボルは次式のとおり定まる.

$$y_i = \begin{cases} x_i + n_i, \ i \le B\\ 0, \ i > B \end{cases}$$
(1)

Low

Dropout ratio

High

ここで,送信シンボル $x_i = z_j + \jmath z_{j+1}$,可用帯域は B とした.

3.3 復号化器

復号化器では無線伝送路を介して潜在変数を受信すると,全結合層に 基づいた復号化関数 g_{ϕ} を用いて潜在変数から対応する 3 次元点群を復 元する.具体的には、重み ϕ にしたがう複数の全結合層と活性化関数 Leaky ReLU との組み合わせと活性化関数 tanh で構成された復号化器 を用いて受信した潜在変数 \hat{z} を 3 次元点群 \hat{p} に復元する.



⊠ 2: Tail Drop

3.4 学習方法

提案手法における符号化関数 f_{θ} の重み θ および復号化関数 g_{ϕ} の重 み ϕ は訓練用データセットに含まれる 3 次元点群と復号後の 3 次元点 群を用いて最適化する.具体的には,元信号となる 3 次元点群と復号後 の 3 次元点群との間の Chamfer distance [4] を最小化するように符号 化関数ならびに復号化関数の重みを学習する. Chamfer distance は次 式にしたがう.

$$d = \frac{1}{2} \left\{ \frac{1}{|S|} \sum_{\boldsymbol{p} \in S} \min_{\widehat{\boldsymbol{p}} \in \widehat{S}} \|\boldsymbol{p} - \widehat{\boldsymbol{p}}\|_2 + \frac{1}{|\widehat{S}|} \sum_{\widehat{\boldsymbol{p}} \in \widehat{S}} \min_{\boldsymbol{p} \in S} \|\boldsymbol{p} - \widehat{\boldsymbol{p}}\|_2 \right\}$$
(2)

ここで、Sは元信号となる3次元点群の集合、 \hat{S} は復号後の3次元点群 の集合を表す. Chamfer distance を小さくするように符号化関数・復 号化関数の重みを学習することで、無線伝送路を介して得られた3次元 点群の各点を元の3次元点群の各点に近づけることが可能となる.

また、学習時においては所望の関数にしたがって潜在変数を Tail Drop [3] させながら符号化関数・復号化関数の重みを学習する. 図 2 に Tail Drop の概略図を示す. Tail Drop では、潜在変数のうち, Tail, す なわち末尾の潜在変数を連続的にドロップアウトする. 潜在変数を連続 的にドロップアウトさせるために、先頭から末尾の潜在変数になればな るほどドロップアウトさせることで、先頭の変数ほど重要な情報を 含むように潜在変数を学習することが可能となる. このとき、各ユーザに 対して先頭の潜在変数から伝送することで潜在変数のレートレス伝送が 可能となる. なお、先頭から末尾の潜在変数に対して定めるドロップア ウト率は任意の分布関数を用いることができる. 提案手法では式 (3) に 示す、べき分布を用いて各潜在変数に対するドロップアウト率を定めた.

$$l = r^{\beta} \tag{3}$$

lは全潜在変数のうち先頭から残す潜在変数の割合, rは [0,1] までの一様乱数, β は事前に定めたパラメータである. 訓練エポック数は 200 エ ポックと定めた. また,各訓練エポックでは異なる rを用いた.

4 性能評価

4.1 評価環境

本稿では提案手法による無線点群伝送品質を評価するために、データ セットとして ShapeNet を用いた. ShapeNet は "Airplane", "Bag", "Cap" に挙げられる複数のカテゴリから構成される.本評価ではカテゴ リ "Airplane"を用いた. 訓練データとして 2,115 個の点群,評価デー タとして 234 個の点群を用いた.

比較手法として PCL, Draco, GNN を用いた点群伝送手法 [5] を用 意した. PCL および Draco から得られたビット列は binary phase-shift keying (BPSK) を用いて無線伝送するものとした. 既存手法 [5] は Tail Drop を利用せず GNN を用いて点群を圧縮するとともにアナログ変調 を用いて潜在変数を無線伝送するものとした. GNN を用いた点群伝送 手法ならびに提案手法は無線伝送路品質が 20 dB である環境を想定して ネットワーク構造を学習するものとした.

品質指標として式 (2) に示した Chamfer distance を用いた.

4.2 評価結果

図3に無線伝送路品質に対する各手法の Chamfer distance を示す. すべての手法において点群伝送に要する帯域を揃えることは困難である



図 3: 無線伝送路品質に対する Chamfer distance

ため,提案手法が必要とする帯域を基準として PCL,Draco の符号化パ ラメータを定めた.各手法において必要となる帯域は凡例に示した.また,PCL や Draco において受信ビット列から点群を復元できなかった 場合は Chamfer distance を 1.0 と定めた.評価結果から以下のことが 分かる.

- 提案手法は無線伝送路品質に応じて受信後の点群品質を改善できること
- 無線伝送路品質が低いユーザに対して Draco や PCL を用いた場合、点群が復元できないこと
- GNNを用いた点群伝送手法は著しい点群品質の低下を抑制する一方で、復元後の点群品質が低いこと

図4に可用帯域が異なる4ユーザに対して各手法を用いて点群をマ ルチキャスト伝送した場合における Chamfer distance を示す. 提案手 法においては可用帯域が限られているユーザに対しても低い Chamfer distance を達成することができるが,可用帯域が10,000 (symbols) で あるときは Chamfer distance が著しく悪化する. GNN を用いた点群 伝送手法においては各ユーザの可用帯域によらず Chamfer distance が 大きくなることが分かった. Draco においてはマルチキャスト対象となっ たユーザの中で最も低い可用帯域に合わせて点群を伝送するため,可用帯 域が大きいユーザはその猶予を点群品質向上に活用することができない.

5 おわりに

本稿ではグラフニューラルネットワークを用いたレートレス点群伝送 手法を提案した.評価結果より,各ユーザの可用帯域が異なる場合,伝 送路品質が異なる場合においても,各ユーザに対して高品質の3次元点 群を提供できることがわかった.

謝辞

本研究は JSPS 科研費 (JP19H01101, JP22H03582) の支援の下で行った.

参考文献

- [1] "Draco 3D data compression," https://google.github.io/draco/.
- [2] R.B. Rusu, and S. Cousins, "3D is here: Point cloud library (pcl)," 2011 IEEE International Conference on Robotics and Automation, pp.1-4, 2011.
- [3] T. Koike-Akino, and Y. Wang, "Stochastic bottleneck: Rateless auto-encoder for flexible dimensionality reduction," IEEE International Symposium on Information Theory (ISIT), pp.2735–2740, 2020.
- [4] S. Chen, C. Duan, Y. Yang, D. Li, C. Feng, and D. Tian, "Deep unsupervised learning of 3d point clouds via graph topology inference and filtering," IEEE Transactions on Image Processing, vol.29, pp.3183-3198, 2020.
- [5] T. Fujihashi, T.K. Akino, S. Chen, and T. Watanabe, "Wireless 3D point cloud delivery using deep graph neural networks," IEEE International Conference on Communications, pp.1–6, 2021.



図 4: 可用帯域が異なるユーザへのマルチキャスト時における Chamfer distance