

DOI: 10.13382/j.jemi.B2307167

一种基于类小波变换的无线电频谱 监测数据无损压缩方法*

张承琰¹ 郑明魁¹ 刘会明² 易天儒¹ 李少良¹ 陈祖儿¹

(1. 福州大学物理与信息工程学院 福州 350108; 2. 福建省无线电监测站 福州 350003)

摘要:无线电频谱监测海量数据存储和分析是无线电监管工作的重要组成部分。频谱数据具有时间相关性以及不同频点间的相关冗余,对此本文设计了一种基于类小波变换的无线电频谱监测数据无损压缩方法。该方法首先基于时间相关性将一维频谱信号转换成二维矩阵;转换成二维矩阵后数据在水平方向以及垂直方向都存在冗余,算法采用卷积神经网络来代替传统小波中的预测和更新模块,并引入了自适应压缩块来处理不同维度的特征,从而获得更紧凑的频谱数据表示。研究进一步设计了一种基于上下文的深度熵模型,利用类小波变换不同子带系数获得熵编码参数,以此估计累积概率,从而实现频谱数据的压缩。实验结果表明,与已有的 Deflate 等传统频谱监测数据无损压缩方法相比,本文算法有进一步的性能提升,与典型的 JPEG2000、PNG、JPEG-LS 等二维图像无损压缩方法相比,本文所提出的方法的压缩效果也提高了 20% 以上。

关键词: 频谱监测数据;无损压缩;类小波变换;卷积神经网络;熵编码

中图分类号: TP391;TN98 **文献标识码:** A **国家标准学科分类代码:** 520.6099

Lossless compression method for radio spectrum data based on wavelet-like transform

Zhang Chengyan¹ Zheng Mingkui¹ Liu Huiming² Yi Tianru¹ Li Shaoliang¹ Chen Zuer¹

(1. College of physics and information engineering, Fuzhou University, Fuzhou 350108, China;

2. Fujian Radio Monitoring Station, Fuzhou 350003, China)

Abstract: The monitoring and analysis of massive data from radio spectrum monitoring are essential components of radio regulation work. To address this, the paper proposes a lossless compression method based on wavelet-like transform for radio spectrum monitoring data. This method first converts the one-dimensional spectrum signal into a two-dimensional matrix based on temporal correlation. Once transformed into a two-dimensional matrix, there is redundancy in both the horizontal and vertical directions. The algorithm employs a convolutional neural network to replace the prediction and update modules in traditional wavelet transform, and introduces an adaptive compression block to handle features of different dimensions, thereby obtaining a more compact representation of spectrum data. Furthermore, the paper designs a context-based deep entropy model, which utilizes the wavelet-like transform's different subband coefficients to obtain entropy coding parameters, estimating cumulative probabilities to achieve spectrum data compression. Experimental results indicate that the proposed algorithm achieves additional performance improvements compared to existing traditional lossless compression methods for spectrum data, such as Deflate. Moreover, when compared with typical two-dimensional image lossless compression methods like JPEG2000, PNG, and JPEG-LS, the proposed method achieves over 20% better compression effectiveness.

Keywords: spectrum monitoring data; lossless compression; wavelet-like transform; convolutional neural network; entropy coding

收稿日期: 2023-12-29 Received Date: 2023-12-29

* 基金项目: 国家自然科学基金(61902071)、福建省重大专项专题项目(2022HZ026007)、福州市科技重大项目(2022-ZD-002)、福建省无线电监测站技术开发项目(01102220)资助

0 引言

由于各种移动设备的增多和宽带通信业务需求^[1-2],为满足频谱资源,频谱监测与管理成为一大难题,无线电管理机构在监测频谱时会产生海量的监测数据,监测原始数据高效压缩编码成为日益迫切的现实需要。

近年来,频谱数据压缩方法主要分为两类:基于统计模型和基于字典的传统方法,以及基于神经网络的方法。基于统计模型的方法包括霍夫曼编码和算术编码^[3-4]。基于字典的方法有 LZ77 和 LZW 等^[5]。文献[6-8]中,分别采用一些基于字符的改进压缩方法进行压缩虽然提高了压缩效果,但是缺失了重构精度,重构时会丢失部分数据。针对无损频谱压缩,文献[9-11]设计并实现一个频谱监测系统,通过比较 LZ77 算法、LZW 算法、Huffman 算法和 Deflate 算法这 4 种无损压缩方法,得出 Deflate 算法有着目前最好的压缩效果。然而,这些方法都是通过固定的规则实现的,无法同时实现高压缩率和高重构精度。

近期深度学习方法在频谱压缩领域得到了应用。一些研究提出了新的思路,如文献[12]提出了一种高效的异构边缘云学习框架和基于孤立点可处理注意力的非对称压缩算法。该算法可实现对异构并行频谱数据的高效压缩和重建,以实现高压缩率。文献[13-14]构建了基于 JPG 算法的电磁频谱监测数据压缩模型。它们将频谱数据转换为灰度图像,并使用神经网络提取图像之间的相关特征,以提高压缩效果。这两篇文章提供了一种频谱数据压缩的新思路,将一维的频谱数据转换到二维空间,并运用神经网络来提取不同维度的相关特征,以达到更好的压缩效果。然而,上述方法虽然压缩率较高,但在无线电监测数据转换为灰度图像时可能会丢失大量数据,从而在重构时无法完美地复现频谱的原始数据。

频谱数据压缩与传统的图像数据压缩等方法有所区别。首先,频谱数据会受到外界和设备干扰,会产生离群频谱数据,增加了压缩存储的难度和开销。在处理离群频谱数据,可能需要更复杂的算法来准确地压缩这些数据,从而增加了计算成本和存储需求。此外,正常的频谱数据分布较为集中,有着明显的特征,而离群数据具有稀疏性^[15],传统的数据压缩算法难以适用离群数据的稀疏性,导致压缩效率低等问题。最后,频谱数据在局部范围内以及相邻频率之间存在相关性,甚至有些频点的监测数据会无差别地重现这一特征。

为了解决上述问题,本文提出了一种基于类小波变换的无线电频谱数据无损压缩方法。该方法首先通过维度转换将一维频谱数据转换成二维矩阵,以提升频谱数据间的多维相关性。接着,采用基于神经网络的类小波变换来提取频谱数据中不同维度的特征,并生成不同尺

度的子带系数。最后,通过深度熵模块确定输出熵参数,用于确定后续算术编码的概率分布。本文方法充分利用了类小波变换的多分辨率分析能力、局部化特性和灵活性,能够更好地适应频谱数据的特点。通过充分捕捉频谱数据的相关信息,解决了传统的频谱压缩方法在处理高频数据时可能存在一些局限性,从而实现了更好的压缩性能。

1 频谱数据特点及分析

电磁频谱数据是刻画电磁频谱态势的量化数字集合,频谱数据在不同维度都有着相关性,在局部范围内的频谱数据和相邻频率上的数据存在冗余。这些存在的冗余为频谱数据的压缩提供了可能,可以使用合适的无损压缩方法,对频谱数据存储方式进行编码优化,在不影响频谱数据内容的基础上还能达到节省数据空间的目的,从而加快数据的压缩速度,减少存储空间。本文对监测产生的数据集进行分析,观察电磁频谱态势以及频谱数据的特点,通过掌握其整体的变化规律为下一步无损编码奠定基础。

如图 1 所示,以下展示了随机两组频谱文件的频谱图,频谱数据的采样频率在 30~3 000 MHz,可以看出不同频率的采样点的幅度都在 -50~100,整体数据幅度值波动比较平缓,大多数数据的幅度变化波动不大,但也存在少量的幅度值变化较大的异常数据。但是不同文件之间的频谱数据分布情况不同,数据间的分布情况也不同。

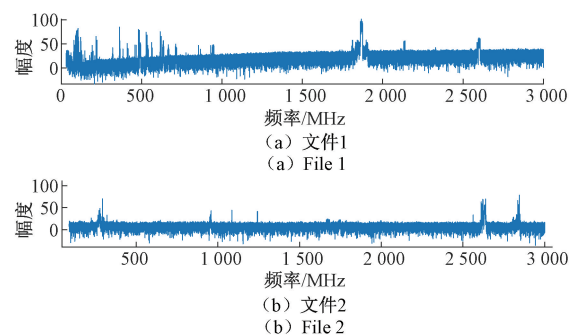


图 1 频谱图

Fig. 1 Spectrogram

对上述数据进行预测,将 30~3 000 MHz 的前一个频谱数据幅值减去后一个频谱数据幅值得到预测残差,预测方法如式(1)所示。

$$Y = X_i - X_{i-1} \quad (1)$$

其中, Y 表示残差结果, X_i 表示第*i*个频点的频谱数据样值, X_{i-1} 表示第*i-1*个频点的频谱数据样值。

经过残差处理后的频谱数据如图 2 所示,前后频谱

数据值幅度大小相差较小,并且密集集中在“0”附近。采用直方图进一步统计频谱数据的预测残差的分布。

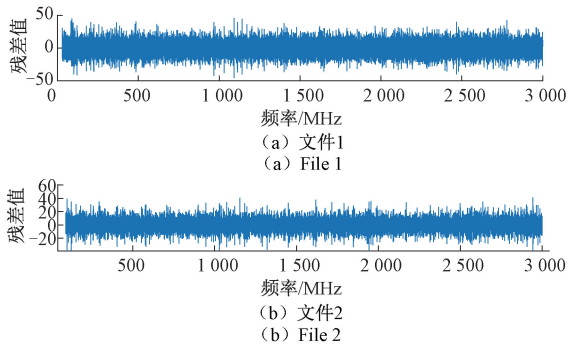


图 2 预测残差波形图

Fig. 2 Waveform of the predicted residuals

两组文件的预测残差概率分布直方图如图 3 所示,可以清晰的看出,预测残差概率分布类似正态分布,大部分残差幅值在零值附近,并且随着残差幅度值的增多,统计量也随之减少。当残差幅度值的绝对值超过 20 以后,统计量几乎趋近于 0。综上所述,不同频率下的采样点的监测数据整体变化较为平缓,较少部分监测数据波动较大,并且相邻采样点之间的幅度差值变化聚集在“0”附近,各采样点频率之间的监测数据具有相关性,存在冗余,为后续进一步的压缩编码等处理提供了可能。

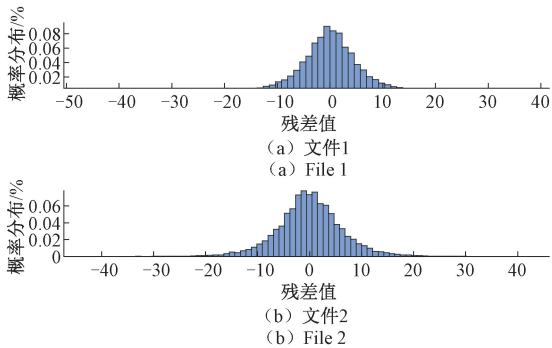


图 3 预测残差概率分布直方图

Fig. 3 Histogram of the predicted residual probability distribution

2 基于提升类小波的频谱数据无损编码方法

2.1 编码框架概述

如上述实验分析,频谱数据在局部范围内以及相邻频率之间存在着较大的冗余空间,甚至有些频点的监测数据会无差别的重现这一特征。故利用频谱数据这一特性,考虑将一维的频谱数据转化成具有图像特征的二维数据进行后续编码,从而达到更好的压缩效果。

本文编码框架如图 4 所示,频谱数据中每一段数据包含头信息和频点样值数据两个部分,头信息中包含该频谱数据的一些设备信息等,频点样值数据是后续需要进行压缩处理的部分。本文将原频谱样值数据进行维度转换,得到一个二维矩阵,转换后频谱数据与图像数据具有较多相似的特性,将经过维度转换的二维矩阵送入基于 CNN 的类小波变换进行训练来提高能量集中性,从而得到一系列能量更集中的小波系数。然后将得到的小波系数送入深度熵模块,利用上下文模型提取经过类小波变换后频谱数据中子带内与子带间的信息,将子带间与子带内的信息相结合,输出熵参数 ψ 用于确定后续算术编码的概率分布。

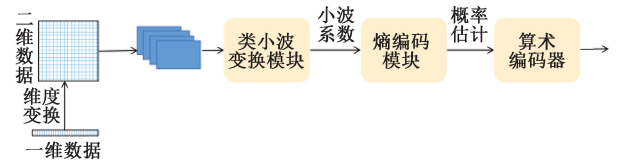


图 4 频谱无损编码框架

Fig. 4 Spectrum lossless coding framework

2.2 类小波变换模块

传统上,小波是在对信号有一定假设的情况下从信号处理理论中设计出来的,但是对频谱数据处理并不像理论中假设的那样理想,仍存在局限性。首先,二维小波变换可以理解成对不同方向的小波进行一维变换,这导致在处理既不是水平也不是垂直的特征时效率低下,难以提取到频谱数据周围的二维信息。其次,小波变换通常是统一执行,在同一尺度下,小波变换可能无法同时准确捕捉到信号的快速变化和频率信息,较高频率的小波函数具有更好的时间分辨率。最后,视频编码技术主要基于 DCT,引入自适应变换核和不同的帧内预测模式来提取局部变换特征,但是这些技术很难在小波变换中实现。为了弥补上述局限性,故提出类小波变换来适应不同方向的特征,如脊波^[16-17]、曲波^[18]、轮廓波^[19]等。但是这些变换会产生太多的变换系数,从而无法有效的压缩。鉴于卷积神经网络具有层次性结构,可以逐层提取数据的特征,并且有着较好的鲁棒性,可以处理频谱数据中的噪声干扰等影响,文献[20]提出一种有效的算法,采用端到端方式训练小波。该算法可以适当缩放小波产生的系数并且进行了大量的实验来验证该算法中小波变换在处理特定类型的不规则纹理图像的有效性。该算法提出将传统提升类小波变换中预测与更新操作采用 CNN 模块替代,这种方法在自然图像上有着不错的效果,但是在频谱中无法较好的学习到频谱在一维上的频率特性和时间特性,也不能更好的融合频谱中不同维度的特征。故本文构建一个非对称卷积模块,利用 1×3 、 3×1 以及 3×3

卷积核分别并行提取频谱数据的不同方向的特征信息,从而更好的去适应不同尺度的特征信息和捕捉频谱图像中任意方向的二维特征,并不局限于水平或者垂直方向的一维特征信息。

对于传统的提升小波变换,主要由拆分、预测、更新这3个步骤组成。而本文提出的类小波变换示意图如图5所示,相较于传统小波,其中更新和预测模块都采用非对称卷积模块替代,并且相较于传统的小波变换,整个小波过程中会经过 N 次更新预测步骤,从而更好的学习到频谱数据间的相关特征。其中更新预测模块的结构图如图6所示,在 N 个提升步骤之后,获得 l_n 和 h_n 分别作为小波系数的低频分量和高频分量。鉴于频谱数据在不同维度上存在冗余,故采用 3×3 的卷积的侧面并行了 1×3 和 3×1 两个非对称卷积核来构建一个非对称卷积模块,这种结构不仅强化了水平方向和垂直方向的特征提取,而且处理了不同维度的特征。其中ACB模块如图7所示,因为频谱数据有着二维的频率特性和时间特性,其中 $1 \times 3, 3 \times 1$ 分别用于提取频谱数据内每一行中不同频率的相关特征和每一列上不同时间的相关特征,同时因为频谱是密集的,需要使用一个 3×3 的卷积核来提取频谱数据的不同采样时间以及不同采样频率之间的二维相关性,并获得其中稀疏特征。




图5 提升小波变换

Fig. 5 Lifting schematic wavelet-like transform




图6 基于神经网络类小波结构

Fig. 6 Neural network based class wavelet structure diagram

图8显示的是本文使用的基于神经网络的类小波变换对频谱数据二维矩阵的三阶分解过程,可以将小波变换分解过程看成沿行和列两个方向的一维小波变换分解。基本过程可以理解成将二维矩阵数据从从尺度 $J+1$ 开始,经三级小波变换逐层分别分解到尺度 $J, J-1, J-2$ 的过程,经过分解后,可以得到许多不同的尺度和方向上的子系数。其中位于左上角的低频子系数包含了二维频




图7 ACB块结构

Fig. 7 ACB block structure diagram

谱数据的大部分信息,而其余高频子系数反映了不同尺度和方向上的细节边缘信息,不同尺度的子系数之间均具有一定的相关性。具体实现过程如下:对于一个输入的频谱数据二维矩阵,依次对其做行列变换计算,此时会得到4个子带LL1、LH1、HL1、HH1,每个子带为原来的 $1/4$ 大小,然后对其中的子系数LL1继续上述操作,会得到更小的4个子带LL2、LH2、HL2、HH2,最后继续对LL2进行分解,得到更小的子带系数,直到变换结束。




图8 类小波变换对频谱数据二维矩阵的三阶分解过程

Fig. 8 Third-order decomposition of two-dimensional matrices of spectral data by wavelet-like transforms

类小波变换在本文中会产生含有不同频率的子带信息,熵参数推理的具体顺序为 $LL_3 \rightarrow HL_3 \rightarrow LH_3 \rightarrow HH_3 \rightarrow HL_2 \rightarrow LH_2 \rightarrow HH_2 \rightarrow HL_1 \rightarrow LH_1 \rightarrow HH_1$,由左上角能量集中性最高的低频信息开始编码,到右下角高频信息方向扫描,并按照这个顺序依次压缩。

此外,经过训练的神经网络通常采用浮点数,而对于无损压缩的频谱数据需要在整数域工作,故需要在每个 P_i 和 U_i 后面添加一个舍入运算,舍入运算是在训练和推理中执行的,并且训练过程中梯度是反向传播,故在舍入时没有变化。

2.3 熵编码模块

在本文中,熵编码模块主要包括上下文提取模块、概率模型以及算术编码模块。对于上下文提取模块,因为频谱数据在不同采样频率或不同采样时间内采集的数据中存在冗余,并且数据间相关性特别大。受到文献[21-22]的启发,采用RNN和长短期记忆(long short term memory, LSTM)层有助于使用长期记忆,更好的学习数据之间的相关性。但是文献[22]中上下文提取模型在子带内仅采用 3×3 的卷积核来提取图像的二维特征,而在频谱数据中,会导致忽略频谱数据中水平方向与垂直方向的相关性,故而采用ACB模块提取它的已编码子带内

的相关特征。并且在处理不同子带间特征时,会并行地它们的输入网络,这导致会加大训练的复杂度,本文故采用 5 个残差块串联,从而更好地提取当前子带的特征信息,为了避免梯度消失问题,每一个模块间加入一个非线性激活函数 GeLU。仅在上下文融合部分进行融合。整体编码流程如图 9 所示,首先,使用利用残差网络模块来提取当前子带的特征。然后,利用模型间的上下文和模型内的上下文进一步提取不同子带之间和同一子带内的上下文信息通过编码像素的子带。最后,利用上下文合并模型融合上述子带信息,得到一系列熵参数用于概率估计。




图 9 基于上下文的熵编码模块结构

Fig. 9 Structure of context-based entropy coding module

其中已编码子带采用 ACB 模块提取它的子带内的特征,并分别与未编码的子带 S_i 融合,通过提取子带间的特征,然后生成用于当前系数的概率函数的参数。其中,为子带 S_i 中采用 mask 3×3 掩膜卷积通过上下文来预测出可能的输出系数。

首先粗略提取已编码子带信息 L_i ,与当前待编码的系数信息相融合,去除当前子带与已编码子带之间的冗余信息,公式如式(2)所示。

$$L_i = \text{Conv}(\text{recon}(S_1, S_2, \dots, S_{i-1})) \quad (2)$$

将融合后的当前编码系数经过 5 个级联残差块,用 mask 3×3 掩膜卷积来提取子带内的高维特征 L_{wt} ,从而去除子带内的冗余信息,公式如式(3)所示。

$$L_{wt} = N(L_i, S_i) \quad (3)$$

式中: $N(\cdot)$ 表示从 L_i 和 S_i 中提取高维特征 L_{wt} 的掩膜二维卷积层。

在上下文中采用 ACB 模块来提取不同维度的子带信息,从而消除子带间的冗余信息,可以用 $M(\cdot)$ 表示用于从 L_i 中提取高维特征 L_{bt} 的两个级联残差块。公式如下:

$$L_{bt} = M(L_i) \quad (4)$$

将提取的上下文 L_{wt} 、 L_{bt} 进行融合,得到一系列的熵参数 ψ :

$$\psi = G(L_{wt}, L_{bt}) \quad (5)$$

累积概率分布函数来估计可以被设定为 $f_k(x)$, 当

$K = 1$ 时,该函数满足如式(6)~(9)所示。

$$f_1(x) = g_1(H^1 x + b^1) \quad (6)$$

$$g_1(x) = x + a^1 \cdot \tanh(x) \quad (7)$$

其中, $H^1, b^1, a^1 \in R^{3 \times 1}$, 故当 $1 < k < K$ 时:

$$f_k(x) = g_k(H^k x + b^k) \quad (8)$$

$$g_k(x) = x + a^k \cdot \tanh(x) \quad (9)$$

其中, $H^k \in R^{3 \times 3}, b^k, a^k \in R^{3 \times 1}$, 故 $k = K$ 时有:

$$f(x) = \text{sigmoid}(H^K x + b^K) \quad (10)$$

其中, $H^K \in R^{1 \times 3}, b^K \in R$ 。通过上下文模型输出的子带系数来估计累积概率分布,最终熵编码所需的概率分布需要对累积概率分布进行微分实现:

$$p = f'_k \cdot f'_{k-1} \cdots f'_1 \quad (11)$$

3 实验与分析

本次实验是在 ubuntu18.04 系统上,电脑配置是 Intel® Xeon(R) Silver 4210R CPU@ 2.40 GHz×40, NVIDIA GeForce RTX 3090 GPUs。现以福建省某市接收机实际已采集的 7 个文件的监测数据为例,对 30~3 000 MHz 的频率范围进行采样,开始频率为 30 MHz,天线相对地面悬挂高度为 100 m,其扫描步进为 25 kHz,当前扫描段的频率点数量为 118 801。经过维度转换的二维频谱数据大小都设置成 500×442,实验使用 Adam 优化器^[23]对熵模型进行训练,学习速率设置成 10^{-5} ,迭代次数为 1 000 个轮次。

为了验证本文所提出的基于类小波变换的无线电频谱数据无损压缩方法的有效性,采用压缩比来衡量压缩效果。本文方法与文献[9-11]中提出的无线电频谱数据压缩方法中的 Huffman 算法和压缩效果最好的 Deflate 算法进行实验对比。如表 1 所示,可以清晰地看出, Huffman 算法和 Deflate 算法在频谱数据的无损压缩中表现不佳,存在一定的局限性。这些方法都是通过固定的规则实现压缩的,难以充分捕捉频谱数据的相关信息,无法有效适应具有较高的复杂性和噪声干扰频谱数据。相比之下,本文方法能够更好地适应频谱数据的特点,通过将一维频谱数据转换成二维矩阵,经过类小波变换后能够产生包含不同频率信息的子带,并且通过熵编码模块能够学习到频谱数据不同维度的相关特征,并实现更高性能的数据压缩。

表 1 本文方法与其他频谱数据压缩方法对比

Table 1 Comparison between this method and other spectrum data compression methods

压缩方法	压缩率/%
Huffman	79.37
Deflate	64.52
本文方法	29.93

文献[13-14]提供了一种将一维频谱数据转换到二维空间的新思路,他们将频谱数据转换为灰度图像后进行压缩。这些方法虽然压缩率较高,但将无线电监测数据转换为灰度图像时可能会丢失大量数据,导致在重构时无法完美地复现频谱的原始数据。为了解决上述问题,本文对经过维度转换的频谱数据,采用了图像无损压缩编码方法, JPEG2000、PNG、JPEG-LS 等进行实验。如表2所示,经过对比分析发现,尽管 JPEG-LS 相较于文献[9-11]中方法有了明显的性能提升,但与本文方法相比仍存在明显差距。

表2 本文方法与图像无损压缩方法对比

Table 2 Comparison between this method and image lossless compression method

压缩方法	压缩率/%
PNG	65.17
JPEG2000	76.21
JPEG-LS	50.01
本文方法	29.93

本文方法在处理频谱数据时能够充分利用基于神经网络的类小波变换的非线性建模能力能够更准确地捕捉频谱数据的复杂特征和结构。熵编码模块可以通过端到端的训练来优化整个数据处理流程,使得压缩模型能够更好地适应频谱数据的分布特点和数据结构。此外,该网络还具有自适应性和泛化能力,能够适应不同类型和不同特征的频谱数据,从而提高了模型的通用性和适用性。

如图10所示,在本文实验中,展示了解码前后的频谱图,并观察到在30~3 000 MHz 采样频率下,两者的频

谱完全一致。后续采用均方误差 (mean-square error, MSE) 的结果作为评估压缩效果的指标。MSE 是衡量两个图像之间差异的常用指标。在图10(c)中,本文实验结果表明,解码后的数据完美地再现了原始数据,达到了频谱数据无损的目的,即失真为0, MSE 为0。

4 结论

本文提出了一种基于类小波变换的无线电频谱数据无损压缩方法,引入了 CNN 来代替传统小波中的预测和更新模块,并引入了 ACB 模块来处理不同维度的特征,从而获得更紧凑的频谱数据。然后将经变换后得到的不同子带送入构建的熵编码模块中,利用输出的熵参数 ψ 来估计累计概率,从而实现频谱数据的压缩。实验结果表明,本文提出的频谱数据无损压缩方法压缩率约为 29.93%,压缩效果不仅远远超过 Huffman、Deflate 算法等传统的无损压缩方法,而且比常用的 PNG 无损图像压缩以及 JPEG-LS 无损压缩效果也提高了 20% 以上。

本文采用的无线电频谱数据集来自福建省某市的接收机实际采集数据,覆盖了 3 GHz 以下的频谱范围。本文方法利用基于神经网络的类小波变换不仅解决了传统的频谱压缩方法在处理频谱数据时可能存在的一些局限性,还具备多分辨率分析、局部化特性、适应性和灵活性等优点。这些特性使得该方法能够更好地应对不同频率范围的数据,并满足更广泛的频率扩展需求。后续研究可以进一步将本方法应用于更高频率范围的频谱数据集中,以验证其在更广泛频率范围内的适用性和性能表现。

参考文献

[1] PALATTELLA M, DOHLER M, GRIECO L, et al. Internet of Things in the 5G era: Enablers, architecture and business models [J]. IEEE Journal on Selected Areas in Communications, 2016, 34(3): 510-527.

[2] KHOROV E, KRASILOV A, SELNITSKIY I, et al. A framework to maximize the capacity of 5g systems for ultra-reliable low latency communications [J]. IEEE Transactions on Mobile Computing, 2021, 20(6): 2111-2123.

[3] DUDA J. Asymmetric numeral systems [J]. ArXiv preprint arXiv:0902.0271, 2009.

[4] MOFFAT A. Huffman coding [J]. ACM Computing Surveys (CSUR), 2019, 52(4): 1-35.

[5] PU I M. Fundamental Data Compression [M]. Oxford: Butterworth-Heinemann, 2005.

[6] 尉茜茜. 基于模式识别的频谱数据压缩方法研究[D]. 成都: 西华大学, 2018.

WEI Q Q. Research on spectrum data compression method based on pattern recognition [D]. Chengdu:

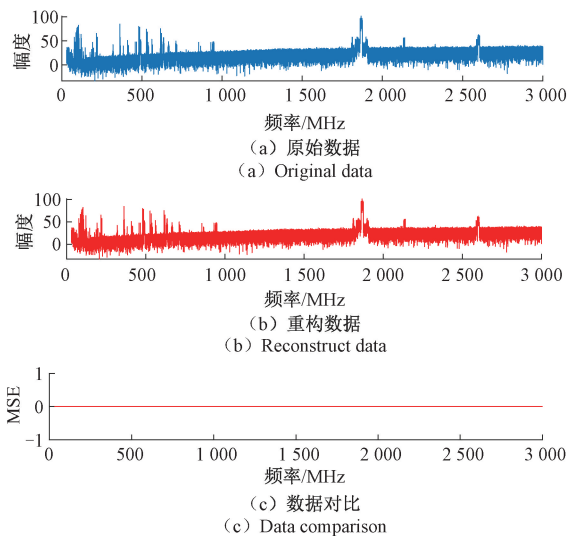


图10 压缩前后频谱数据与绝对误差

Fig. 10 Spectrum data before and after compression with absolute error graph

- Xihua University, 2018.
- [7] 雷啸. 频谱监测数据的有损压缩及压缩并行算法研究[D]. 成都:电子科技大学, 2020.
LEI X. Research on lossy compression and parallel algorithm for spectrum monitoring data [D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [8] ZHOU M, DENG B, KONG M, et al. A real-time spectrum data compression method based on character encoding [C]. 2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP), 2022: 410-414.
- [9] 贾曼鑫. 智能频谱监测系统的关键技术研究与实践[D]. 西安:西安电子科技大学, 2021.
JIA M X. Research and implementation of intelligent technologies of digital spectrum monitoring system [D]. Xi'an: Xidian University, 2021.
- [10] 李昂. 电磁频谱监测系统关键技术与实现[D]. 北京:北京邮电大学, 2016.
LI ANG. Key technologies and implementation of spectrum monitoring system [D]. Beijing: Beijing University of Posts and Telecommunications, 2016.
- [11] 汪紫薇. 电磁频谱监测系统数据传输关键技术研究[D]. 武汉:华中科技大学, 2017.
WANG Z W. Research on key technologies for data transmission for electromagnetic spectrum monitoring system [D]. Wuhan: Huazhong University of Science and Technology, 2017.
- [12] WU G, ZHOU F, DING G, et al. An efficient heterogeneous edge-cloud learning framework for spectrum data compression [J]. IEEE Transactions on Mobile Computing, 2023, 22(7): 3823-3839.
- [13] ZHANG X. Design and implementation of electromagnetic spectrum monitoring data compression based on JPG algorithm [C]. 2022 IEEE 4th International Conference on Civil Aviation Safety and Information Technology (ICCASIT), IEEE, 2022: 113-116.
- [14] 刘红杰, 陈鹏, 张政, 等. 基于 DCT 自适应量化的频谱数据有损压缩算法[J]. 移动通信, 2024, 48(4): 123-128.
LIU H J, CHEN P, ZHANG ZH, et al. Lossy compression algorithm of spectrum data based on DCT adaptive quantization [J]. Mobile Communications, 2024, 48(4): 123-128.
- [15] GU Y, GOODMAN N A, HONG S, et al. Robust adaptive beamforming based on interference covariance matrix sparse reconstruction [J]. Signal Processing, 2014, 96(2): 375-381.
- [16] CANDES E J. Monoscale ridgelets for the representation of images with edges [J]. Dept. Statist., Stanford Univ., Stanford, CA, Tech. Rep, 1999.
- [17] DO M N, VETTERLI M. The finite ridgelet transform for image representation [J]. IEEE Transactions on Image Process, 2003, 12(1): 16-28.
- [18] CANDES E J, DONOHO D L. Curvelets, multiresolution representation, and scaling laws [C]. Wavelet Applications in Signal and Image Processing VIII. SPIE, 2000, 4119: 1-12.
- [19] DO M N, VETTERLI M. The contourlet transform: An efficient directional multiresolution image representation [J]. IEEE Transactions on Image Processing, 2005, 14(12): 2091-2106.
- [20] MA H, LIU D, XIONG R, et al. iWave: CNN-based wavelet-like transform for image compression [J]. IEEE Transactions on Multimedia, 2020, 22(7): 1667-1679.
- [21] VAN D O A, KALCHBRENNER N, ESPEHOLT L, et al. Conditional image generation with PixelCNN decoders [J]. Advances in Neural Information Processing Systems, 2016, 29.
- [22] MA H, LIU D, YAN N, et al. End-to-end optimized versatile image compression with wavelet-like transform [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(3): 1247-1263.
- [23] ZHANG Z. Improved adam optimizer for deep neural networks [C]. 2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS). IEEE, 2018: 1-2.

作者简介



张承琰, 2020 年于武汉轻工大学获得学士学位, 现为福州大学硕士研究生, 主要研究方向为频谱编码与图像编码。

E-mail: 211127185@fzu.edu.cn

Zhang Chengyan received his B. Sc. degree from Wuhan Polytechnic University in 2020. Now he is a M. Sc. candidate in Fuzhou University. His main research interests include spectrum coding and image coding.



郑明魁(通信作者), 2016 年于福州大学获得博士学位, 现为福州大学副教授, 硕士生导师, 目前主要研究方向为频谱数据处理、点云与视频编码。

E-mail: zhengmk@fzu.edu.cn

Zheng Mingkui (Corresponding author) received his Ph. D. degree from Fuzhou University in 2016. Now he is an associate professor and M. Sc. supervisor in Fuzhou University. His main research interests include radio spectrum data processing, point cloud and video encoding.