

编解码方法、装置及其设备

技术领域

[01]本公开涉及编解码技术领域，尤其是涉及编解码方法、装置及其设备。

背景技术

[02]为了达到节约空间的目的，视频图像都是经过编码后才传输的，完整的视频编码可以包括预测、变换、量化、熵编码、滤波等过程。针对预测过程，预测过程可以包括帧内预测和帧间预测，帧间预测是指利用视频时间域的相关性，使用邻近已编码图像的像素预测当前像素，以达到有效去除视频时域冗余的目的。帧内预测是指利用视频空间域的相关性，使用当前帧图像的已编码块的像素预测当前像素，以达到去除视频空域冗余的目的。

[03]随着深度学习的迅速发展，深度学习在许多高层次的计算机视觉问题上取得成功，如图像分类、目标检测等，深度学习也逐渐在编解码领域开始应用，即可以采用神经网络对图像进行编码和解码。虽然基于神经网络的编解码方法展现出巨大性能潜力，但是，基于神经网络的编解码方法，仍然会存在解码性能较差和复杂度较高等问题。

发明内容

[04]有鉴于此，本公开提供编解码方法、装置及其设备，能够提高解码性能。

[05]第一方面，本公开提供一种解码方法，包括：

[06]对当前图像块对应的码流进行解码得到重建图像块，所述重建图像块包括第一初始分量和第二初始分量，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率；

[07]基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量；

[08]对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量。

[09]在一些实施例中，所述重建图像块为 YUV 格式的重建图像块，所述第一初始分量为亮度分量，所述第二初始分量为色度 U 分量和色度 V 分量。

[10]在一些实施例中，所述基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量，包括：

[11]获取所述第一初始分量对应的第一图像特征，所述第一图像特征包括未经过神经网络的图像特征；

[12]获取所述第二初始分量对应的第二图像特征，所述第二图像特征包括未经过神经网络的图像特征；

[13]基于所述第一图像特征和所述第二图像特征生成所述调整后分量。

[14]在一些实施例中，所述第一图像特征包括 Haar 小波频域特征；所述第二图像特征包括 Haar 小波频域特征。

[15]在一些实施例中,所述基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量,包括:

[16]对所述第一初始分量进行至少一次 Haar 小波变换,得到变换后的多个频带作为第一特征图;

[17]对所述第二初始分量进行至少一次 Haar 小波变换,得到变换后的多个频带作为第二特征图;

[18]对所述第一特征图和所述第二特征图进行拼叠操作,得到所述调整后分量。

[19]在一些实施例中,所述对所述第一特征图和所述第二特征图进行拼叠操作,包括:

[20]沿通道维度对所述第一特征图和所述第二特征图进行拼叠操作。

[21]在一些实施例中,所述对所述第一初始分量进行至少一次 Haar 小波变换,得到变换后的多个频带,包括:对所述第一初始分量进行两次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带;

[22]所述对所述第二初始分量进行至少一次 Haar 小波变换,得到变换后的多个频带,包括:对所述第二初始分量进行两次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带。

[23]在一些实施例中,所述对所述第一初始分量进行多次 Haar 小波变换,得到变换后的多个频带,包括:对所述第一初始分量进行两次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带;

[24]所述对所述第二初始分量进行多次 Haar 小波变换,得变换后的多个频带,包括:对所述第二初始分量进行两次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带。

[25]在一些实施例中,所述对所述第一初始分量进行两次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带,包括:对所述第一初始分量进行第一次 Haar 小波变换,得到第一次 Haar 小波变换后的多个频带;对所述第一次 Haar 小波变换后的多个频带进行第二次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带;

[26]所述对所述第二初始分量进行两次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带,包括:对所述第二初始分量进行第一次 Haar 小波变换,得到第一次 Haar 小波变换后的多个频带;对所述第一次 Haar 小波变换后的多个频带进行第二次 Haar 小波变换,得到所述两次 Haar 小波变换后的多个频带。

[27]在一些实施例中,所述对所述调整后分量进行特征增强,得到所述第二初始分量对应的恢复后的目标分量,包括:

[28]通过多个残差块网络对所述调整后分量进行特征增强,得到所述目标分量。

[29]第二方面,本公开提供一种编码方法,包括:

[30]对当前图像块的第一初始分量和第二初始分量进行编码,得到所述当前图像块对应的码流,其中,所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率。

[31]在一些实施例中,所述当前图像块为 YUV 格式,所述第一初始分量为亮度分量,所述第二初始分量为色度 U 分量和色度 V 分量。

[32]第三方面,本公开提供一种解码装置,包括:

[33]解码模块,用于对当前图像块对应的码流进行解码得到重建图像块,所述重建图像块包括第一初始分量和第二初始分量,所述第一初始分量的分辨率大于或者等于所述第

二初始分量的分辨率;

[34] 确定模块, 用于基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量;

[35] 处理模块, 用于对所述调整后分量进行特征增强, 得到所述第二初始分量对应的恢复后的目标分量。

[36] 第四方面, 本公开提供一种编码装置, 包括:

[37] 编码模块, 用于对当前图像块的第一初始分量和第二初始分量进行编码, 得到所述当前图像块对应的码流, 其中, 所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率。

[38] 第五方面, 本公开提供一种解码端设备, 包括: 处理器和机器可读存储介质, 所述机器可读存储介质存储有能够被所述处理器执行的机器可执行指令; 所述处理器用于执行机器可执行指令, 以实现第一方面中任一实施例所述的方法。

[39] 第六方面, 本公开提供一种编码端设备, 包括: 处理器和机器可读存储介质, 所述机器可读存储介质存储有能够被所述处理器执行的机器可执行指令; 所述处理器用于执行机器可执行指令, 以实现第二方面中任一实施例所述的方法。

[40] 第七方面, 本公开提供一种机器可读存储介质, 所述机器可读存储介质上存储有若干计算机指令, 所述计算机指令被处理器执行时, 实现第一方面中任一实施例所述的方法, 或实现第二方面中任一实施例所述的方法。

[41] 第八方面, 本公开提供一种计算机程序产品, 包括计算机程序, 所述计算机程序被处理器执行时实现第一方面中任一实施例所述的方法, 或实现第二方面中任一实施例所述的方法。

[42] 由以上技术方案可见, 本公开实施例中, 在解码得到重建图像块之后, 重建图像块包括第一初始分量和第二初始分量, 第一初始分量的分辨率大于或者等于第二初始分量的分辨率, 基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量, 即基于第一初始分量辅助对第二初始分量进行调整, 得到调整后分量, 继而基于调整后分量确定第二初始分量对应的目标分量, 从而能够提高解码性能, 降低解码复杂度, 降低计算复杂度, 对资源需求比较少, 对成本、延时敏感的设备也可以使用上述算法, 提出低复杂度且高效的后处理网络模型框架, 针对多种码率下的压缩缺陷恢复。

附图说明

[43] 图 1 是本公开一种实施方式中的三维特征矩阵的示意图;

[44] 图 2 是本公开一种实施方式中的解码方法的流程图;

[45] 图 3 是本公开一种实施方式中的编码端的处理过程示意图;

[46] 图 4 是本公开一种实施方式中的解码端的处理过程示意图;

[47] 图 5A 是本公开一种实施方式中的端到端图像压缩的结构示意图;

[48] 图 5B 是本公开一种实施方式中的基于深度学习的后处理的结构示意图;

[49] 图 6A-图 6I 是本公开一种实施方式中的后处理网络的结构示意图;

[50] 图 7A-图 7C 是本公开一种实施方式中的上采样的示意图;

[51]图 7D 是本公开一种实施方式中的后处理网络的结构示意图；

[52]图 7E 和图 7F 是本公开一种实施方式中的特征增强的示意图；

[53]图 8 是本公开一种实施方式中的解码端设备的硬件结构图。

具体实施方式

[54]在本公开实施例使用的术语仅仅是出于描述特定实施例的目的，而非用于限制本公开。本公开实施例和权利要求书中所使用的单数形式的“一种”、“所述”和“该”也旨在包括多数形式，除非上下文清楚地表示其它含义。还应当理解，本文中使用的术语“和/或”是指包含一个或多个相关联的列出项目的任何或所有可能组合。应当理解，尽管在本公开实施例可能采用术语第一、第二、第三等来描述各种信息，但是，这些信息不应限于这些术语。这些术语仅用来将同一类型的信息彼此区分开。例如，在不脱离本公开实施例范围的情况下，第一信息也可以被称为第二信息，类似地，第二信息也可以被称为第一信息，取决于语境。此外，所使用的词语“如果”可以被解释成为“在……时”，或“当……时”，或“响应于确定”。

[55]本公开实施例中提出一种解码方法，该解码方法可以涉及如下概念：

[56]JPEG (Joint Photographic Experts Group, 联合图像专家组)：JPEG 是用于连续色调静态图像压缩的一种标准，文件后缀名可以为.jpg 或者.jpeg，JPEG 是一种常用的图像文件格式。JPEG 是采用预测编码 (DPCM)、离散余弦变换 (DCT) 以及熵编码的联合编码方式，以去除冗余的图像和彩色数据，属于有损压缩格式，能够将图像压缩在很小的储存空间，一定程度上会造成图像数据的损伤。尤其是使用过高的压缩比例时，将使最终解压缩后恢复的图像质量降低，如果追求高品质图像，则 JPEG 不宜采用过高的压缩比例。

[57]JPEG-AI (Joint Photographic Experts Group Artificial Intelligence, 联合图像专家组-人工智能)：JPEG-AI 的范围是创建基于学习的图像编码标准，提供单流、紧凑的压缩域表示，在同等主观质量下，比常用的图像编码标准显著提高压缩效率，在图像处理和计算机视觉任务中有效提升性能。JPEG-AI 面向广泛的应用，如云存储、视觉管理、自动驾驶汽车和设备、图像采集存储和管理、视觉数据的实时管理和媒体分发等。JPEG-AI 的目标是设计一种编解码解决方案，该解决方案需要以相同的主观质量显著提高压缩效率，为基于机器学习的图像处理和计算机视觉任务提供有效的压缩域处理。JPEG-AI 需要针对硬件和软件实现友好的编码和解码，对 8 位和 10 位深度的支持，使用文本和图形对图像进行高效编码和渐进式解码。

[58]后处理滤波 (Post Filter)：编码端对图像编码压缩形成一串码流，解码端从码流中解码并重构出图像，但是，由于编码算法自身的原因，从码流中解码并重构出图像之后，图像会出现如方块效应、图像伪影和色彩漂移等缺陷，后处理滤波的作用是为了改善图像由编码压缩带来的缺陷，最大程度地恢复图像数据，提高解码重构图像的主观质量。

[59]图像超分 (Image Super-Resolution)：超分 (Super-Resolution) 主要是指将低分辨率的图像 (Low-Resolution) 复原到高分辨率 (High-Resolution) 的图像，同时增强图像细节，改善图像主观质量，图像超分是在计算机视觉图像处理中用于增强图像分辨率的技术。

[60]YUV 色彩空间 (YUV Color Space)：彩色图像的每个像素点通常可以用几个独立的物理量来描述，从而构成一个空间坐标，这就是图像的色彩空间。YUV 色彩空间即是彩色图像的像素点用 Y (亮度)、U (色度)、V (色度) 这三个属性来描述的色彩

空间。

[61]熵编码 (Entropy Encoding)：熵编码即编码过程中按照熵原理不丢失任何信息的编码，信息熵为信源的平均信息量（不确定性的度量）。熵编码的编码方式可以包括但不限于：香农(Shannon)编码、哈夫曼(Huffman)编码和算术编码(arithmetic coding)。

[62]神经网络 (Neural Network, NN)：神经网络是指人工神经网络，神经网络是一种运算模型，由大量节点（或称为神经元）之间相互联接构成。在神经网络中，神经元处理单元可表示不同的对象，如特征、字母、概念，或者一些有意义的抽象模式。神经网络中处理单元的类型可以分为三类：输入单元、输出单元和隐单元。输入单元接受外部世界的信号与数据；输出单元实现处理结果的输出；隐单元是处在输入和输出单元之间，不能由系统外部观察的单元。神经元之间的连接权值反映了单元间的连接强度，信息的表示和处理体现在处理单元的连接关系中。神经网络是一种非程序化、类大脑风格的信息处理方式，神经网络的本质是通过神经网络的变换和动力学行为得到一种并行分布式的信息处理功能，并在不同程度和层次上模仿人脑神经系统的信息处理功能。在视频处理领域，常用的神经网络可以包括但不限于：卷积神经网络(CNN)、循环神经网络(RNN)、全连接网络等。

[63]卷积神经网络 (Convolutional Neural Network, CNN)：卷积神经网络是一种前馈神经网络，是深度学习技术中极具代表的网络结构之一，卷积神经网络的人工神经元可以响应一部分覆盖范围内的周围单元，对于大型图像处理有出色表现。卷积神经网络的基本结构包括两层，其一为特征提取层（也称卷积层），每个神经元的输入与前一层的局部接受域相连，并提取该局部的特征。一旦该局部特征被提取后，它与其它特征间的位置关系也随之确定下来。其二是特征映射层（也称激活层），神经网络的每个计算层由多个特征映射组成，每个特征映射是一个平面，平面上所有神经元的权值相等。特征映射结构可以采用 Sigmoid 函数、ReLU 函数、Leaky-ReLU 函数、PReLU 函数、GDN 函数等作为卷积网络的激活函数。此外，由于一个映射面上的神经元共享权值，因而能够减少网络自由参数的个数。

[64]示例性的，卷积神经网络相较于图像处理算法的优点之一在于，避免了对图像复杂的前期预处理过程（提取人工特征等），可以直接输入原始图像，进行端到端的学习。卷积神经网络相较于普通神经网络的优点之一在于，普通神经网络都是采用全连接的方式，即输入层到隐藏层的神经元都是全部连接的，这样做将导致参数量巨大，使得网络训练耗时甚至难以训练，而卷积神经网络则通过局部连接、权值共享等方法避免了这一困难。

[65]反卷积层 (Deconvolution)：反卷积层又称为转置卷积层，反卷积层和卷积层的工作过程很相似，主要区别在于，反卷积层会通过 padding（填充），使得输出大于输入（也可以保持相同）。若 stride 为 1，则表示输出尺寸等于输入尺寸；若 stride（步长）为 N，则表示输出特征的宽为输入特征的宽的 N 倍，输出特征的高为输入特征的高的 N 倍。

[66]泛化能力 (Generalization Ability)：泛化能力可以是指机器学习算法对新鲜样本的适应能力，学习的目的是学到隐含在数据背后的规律，对具有同一规律的学习集以外的数据，经过训练的网络也能够给出合适的输出，该能力就可以称为泛化能力。

[67]特征 (feature)：本公开中涉及的特征，是一个 $C \times W \times H$ 的三维特征矩阵，参见图 1 所示，是三维特征矩阵的示意图，在三维特征矩阵中，C 表示通道 (channel) 数，H 表示特征高度，W 表示特征宽度。三维特征矩阵可以是神经网络的输入，也可以是神经网络的输出。

[68]率失真原则(Rate-Distortion Optimized):评价编码效率的有两大指标:码率和PSNR(Peak Signal to Noise Ratio, 峰值信噪比), 比特流越小, 则压缩率越大, PSNR 越大, 则重建图像质量越好, 在模式选择时, 判别公式实质上也就是对二者的综合评价。例如, 模式对应的代价: $J(\text{mode}) = D + \lambda * R$, 其中, D 表示 Distortion(失真), 通常可以使用 SSE 指标来进行衡量, SSE 是指重建图像块与源图像的差值的均方和, 为了实时代价考虑, 也可以使用 SAD 指标, SAD 是指重建图像块与源图像的差值绝对值之和; λ 是拉格朗日乘子, R 就是该模式下图像块编码所需的实际比特数, 包括编码模式信息、运动信息、残差等所需的比特总和。在模式选择时, 若使用率失真原则去对编码模式做比较决策, 通常可以保证编码性能最佳。

[69]针对编码端的各个模块, 提出了非常多的编码工具, 而每个工具往往又有多种模式。对于不同视频序列, 能获得最优编码性能的编码工具往往不同。因此, 在编码过程中, 通常采用 RDO(Rate-Distortion Optimize)比较不同工具或模式的编码性能, 以选择最佳模式。在确定最优工具或模式后, 再通过比特流中编码标记信息的方法传递工具或模式的决策信息。这种方法虽然带来了较高的编码复杂度, 但可以针对不同内容, 自适应选择最优的模式组合, 获得最优的编码性能。解码端可通过直接解析标志信息获得相关模式信息, 复杂度影响较小。

[70]在基于深度学习的端到端图像压缩技术中, 图像会被转换为 YUV 色彩空间, 并对 UV 色度信号进行二分之一下采样, 然后 Y 信号和 UV 信号被分别压缩编码。解码端根据比特流数据进行解码重构, 得到重构后的 Y 信号和 UV 信号, 由于 UV 色度信号是进行二分之一下采样后进行压缩编码, 即 UV 色度信号的分辨率减半, 因此, 在后处理过程中, 还可以对 UV 色度信号的分辨率进行恢复, 而该分辨率恢复过程的计算复杂度较高, 且对资源的需求比较大, 一些对成本、延时敏感的设备无法对 UV 色度信号的分辨率进行恢复。

[71]针对上述发现, 本实施例中提出一种基于神经网络的去压缩缺陷网络模型方法, 在端到端的图像压缩领域中, 提出一种低复杂度且高效的后处理网络模型框架, 能够基于 Y 信号对 UV 信号进行增强, 该方法复杂度较低且性能较高, 可以针对多种码率下的压缩缺陷恢复。

[72]以下结合几个具体实施例, 对本公开实施例中的解码方法进行详细说明。

[73]实施例 1: 本公开实施例中提出一种解码方法, 参见图 2 所示, 为该解码方法的流程图示意图, 该方法可以应用于解码端(也称为视频解码器), 该方法可以包括步骤 201-203。

[74]步骤 201、对当前图像块对应的码流进行解码得到重建图像块。

[75]示例性的, 重建图像块可以包括第一初始分量和第二初始分量, 第二初始分量的分辨率是经过下采样的分辨率, 且第一初始分量的分辨率可以大于或者等于第二初始分量的分辨率。比如说, 第一初始分量的分辨率可以是未经过下采样的分辨率(即原始分辨率), 也可以是经过下采样的分辨率, 但是第一初始分量的分辨率大于或等于第二初始分量的分辨率, 对此不作限制。

[76]示例性的, 若重建图像块为 YUV 格式的重建图像块, 则第一初始分量可以为亮度分量, 第二初始分量可以为色度 U 分量和/或色度 V 分量; 或者, 若重建图像块为 RGB 格式的重建图像块, 则第一初始分量可以为 G 分量, 第二初始分量可以为 R 分量和/或 B 分量。

[77]步骤 202、基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量。调整后分量的重建质量可以优于第二初始分量的重建质量, 调整后分量的重建质量可以等于第二初始分量的重建质量, 第二初始分量的重建质量也可以优于调整后分量的重建

质量。

[78] 示例性的，可以获取第一初始分量对应的第一图像特征，该第一图像特征可以包括但不限于未经过神经网络的图像特征和/或经过神经网络的图像特征；可以获取第二初始分量对应的第二图像特征，该第二图像特征可以包括但不限于未经过神经网络的图像特征和/或经过神经网络的图像特征；可以基于该第一图像特征和该第二图像特征生成调整后分量。

[79] 示例性的，若第一图像特征包括未经过神经网络的图像特征，则第一图像特征可以包括但不限于以下至少一种：纹理特征、主观特征、频域特征、或直方图特征；若第二图像特征包括未经过神经网络的图像特征，则第二图像特征可以包括但不限于以下至少一种：纹理特征、主观特征、频域特征、或直方图特征。上述只是几个示例，对此不作限制。

[80] 若第一图像特征包括经过神经网络的第一特征图，第二图像特征包括经过神经网络的第二特征图，基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量，可以包括但不限于：将该第一初始分量输入给第一神经网络，得到第一特征图；将该第二初始分量输入给第二神经网络，得到第二特征图；对该第一特征图和该第二特征图进行相加操作，得到调整后分量；或者，对该第一特征图和该第二特征图进行拼叠操作，得到调整后分量。

[81] 示例性的，若第一图像特征包括经过神经网络的权重系数图，第二图像特征包括经过神经网络的第二特征图，基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量，可以包括但不限于：将该第一初始分量输入给第一神经网络，得到该第一初始分量对应的第一特征图，并对第一特征图进行引导滤波，得到权重系数图；将该第二初始分量输入给第二神经网络，得到第二特征图；基于该权重系数图和该第二特征图生成调整后分量。

[82] 示例性的，对第一特征图进行引导滤波，得到权重系数图，可以包括但不限于：对第一特征图进行卷积操作，得到卷积后特征图；对卷积后特征图进行权重映射，得到权重系数图。

[83] 示例性的，对卷积后特征图进行权重映射，得到权重系数图，包括但不限于：对卷积后特征图进行池化操作，得到池化操作后特征图；对池化操作后特征图进行全连接操作和 ReLU (Rectified Linear Unit, 修正线性单元) 激活操作，得到 ReLU 激活操作后特征图；对 ReLU 激活操作后特征图进行全连接操作和 Sigmoid (S 形曲线，即 S 形函数) 激活操作，得到 Sigmoid 激活操作后特征图；基于卷积后特征图和 Sigmoid 激活操作后特征图生成权重系数图，卷积后特征图和 Sigmoid 激活操作后特征图相乘得到权重系数图。

[84] 示例性的，对卷积后特征图进行权重映射，得到权重系数图，可以包括但不限于：可以对卷积后特征图进行卷积操作以及 Sigmoid 激活操作，得到权重系数图。

[85] 示例性的，基于该权重系数图和该第二特征图生成调整后分量，可以包括但不限于：对该权重系数图和该第二特征图进行相乘操作，得到相乘后特征图；对该第一特征图进行卷积操作，得到卷积后特征图；对相乘后特征图和卷积后特征图进行相加操作，得到相加后特征图；对相加后特征图和卷积后特征图进行拼叠操作，得到调整后分量。

[86] 示例性的，若第一图像特征包括经过神经网络的 K 个第一特征图，且第二图像特征包括经过神经网络的 K+1 个第二特征图，基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量，可以包括但不限于：针对首个第一特征图和首个第二特征图，可以将该第一初始分量输入给神经网络得到首个第一特征图，并将该第二初始分量输入

给神经网络得到首个第二特征图。针对第 i 个第一特征图和第 i 个第二特征图, i 为大于等于 2 且小于等于 K 的任一整数, K 可以为大于 1 的正整数, 那么, 可以将第 $i-1$ 个第一特征图输入给神经网络得到第 i 个第一特征图; 对第 $i-1$ 个第一特征图和第 $i-1$ 个第二特征图进行特征融合得到融合后特征, 并将融合后特征输入给神经网络得到第 i 个第二特征图; 在得到第最后一个第二特征图(即 $K+1$ 个第二特征图中的最后一个第二特征图)之后, 可以基于最后一个第二特征图生成调整后分量。

[87] 示例性的, 对第一特征图(如第 $i-1$ 个第一特征图)和第二特征图(如第 $i-1$ 个第二特征图)进行特征融合得到融合后特征, 可以包括但不限于: 对该第一特征图和该第二特征图进行相加操作, 得到融合后特征; 或者, 对该第一特征图和该第二特征图进行拼叠操作, 得到融合后特征; 或者, 对该第一特征图进行引导滤波, 得到第一特征图对应的权重系数图, 并基于权重系数图和该第二特征图生成融合后特征。上述只是几个示例, 对此不作限制。

[88] 示例性的, 将第一初始分量输入给第一神经网络, 得到第一特征图, 可以包括但不限于: 从第一初始分量中提取 M 个维度的图像特征, M 为正整数; 对 M 个维度的图像特征进行拼叠, 得到拼叠后的多维度特征; 将多维度特征输入给第一神经网络, 得到第一特征图。

[89] 示例性的, M 个维度的图像特征可以包括但不限于以下至少一种: 采用一个卷积核对第一初始分量进行卷积后的图像特征; 采用两个卷积核对第一初始分量进行卷积级联后的图像特征; 采用 sobel(索贝尔)算子对第一初始分量进行处理后的一阶空域特征; 采用 Laplacian(拉普拉斯)算子对第一初始分量进行处理后的二阶空域特征; 或对第一初始分量进行傅里叶变换后的频域特征。上述只是图像特征的几个示例, 对此不作限制。

[90] 示例性的, 将第一初始分量输入给第一神经网络, 得到第一特征图, 可以包括但不限于: 对第一初始分量进行小波变换, 得到小波变换后的多个频带; 将多个频带或者多个频带中的部分频带输入给第一神经网络, 得到第一特征图。将第二初始分量输入给第二神经网络, 得到第二特征图, 可以包括但不限于: 对第二初始分量进行小波变换, 得到小波变换后的多个频带; 将多个频带或者多个频带中的部分频带输入给第二神经网络, 得到第二特征图。

[91] 在对第一初始分量进行小波变换, 得到小波变换后的多个频带时, 可以对第一初始分量进行一次小波变换, 得到小波变换后的多个频带, 也可以对第一初始分量进行多次小波变换, 得到小波变换后的多个频带。在对第一初始分量进行多次小波变换时, 先对第一初始分量进行小波变换, 得到小波变换后的多个频带, 然后, 从多个频带中选取目标频带(多个频带中的全部频带或者部分频带), 对目标频带进行小波变换, 得到小波变换后的多个频带, 以此类推, 一直到完成小波变换, 得到小波变换后的多个频带。在对第二初始分量进行小波变换, 得到小波变换后的多个频带时, 可以对第二初始分量进行一次小波变换, 得到小波变换后的多个频带, 也可以对第二初始分量进行多次小波变换, 得到小波变换后的多个频带。

[92] 示例性的, 将第一初始分量输入给第一神经网络, 得到第一特征图之前, 还可以对第一初始分量进行预处理, 得到预处理后的第一初始分量; 其中, 预处理后的第一初始分量用于输入给第一神经网络得到第一特征图。其中, 对第一初始分量进行预处理, 得到预处理后的第一初始分量, 可以包括但不限于: 对第一初始分量进行边缘增强, 得到边缘增强后的图像特征; 对边缘增强后的图像特征进行多尺度的特征提取, 得到多尺度特征; 基于多尺度特征预处理后的第一初始分量, 如多尺度特征作为预处理后的第一初始分量。

[93] 示例性的, 对边缘增强后的图像特征进行多尺度的特征提取, 得到多尺度特征, 可

以包括但不限于：对边缘增强后的图像特征进行卷积操作，得到卷积后特征；对卷积后特征进行下采样操作，得到下采样后特征；对下采样后特征进行通道变换，得到通道变换后特征；对通道变换后特征进行上采样操作，得到上采样后特征；基于上采样后特征和通道变换后特征生成多尺度特征，然后，将多尺度特征作为预处理后的第一初始分量输入给第一神经网络。

[94] 步骤 203、对调整后分量进行特征增强，得到第二初始分量对应的恢复后的目标分量。

[95] 在一种可能的实施方式中，在基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量之前，还可以对第二初始分量进行上采样，得到上采样后的第二初始分量。其中，上采样后的第二初始分量的分辨率可以等于第一初始分量的分辨率。

[96] 在另一种可能的实施方式中，在对调整后分量进行特征增强，得到第二初始分量对应的恢复后的目标分量之前（即步骤 203 之前），还可以对调整后分量进行上采样，得到上采样后的调整后分量。其中，上采样后的调整后分量的分辨率可以等于第一初始分量的分辨率。

[97] 在另一种可能的实施方式中，在对调整后分量进行特征增强，得到第二初始分量对应的恢复后的目标分量之后（即在步骤 203 之后），还可以对目标分量进行上采样，得到上采样后的目标分量。其中，上采样后的目标分量的分辨率可以等于第一初始分量的分辨率。

[98] 示例性的，对调整后分量进行特征增强，得到第二初始分量对应的恢复后的目标分量，可以包括但不限于：通过至少一个残差块网络对调整后分量进行特征增强，得到第二初始分量对应的目标分量；或者，通过 U-Net（Encoder-Decoder 结构的网络，前半部分是特征提取，后半部分是上采样）网络对调整后分量进行特征增强，得到第二初始分量对应的目标分量。

[99] 示例性的，上述执行顺序只是为了方便描述给出的示例，在实际应用中，还可以改变步骤之间的执行顺序，对此执行顺序不做限制。而且，在其它实施例中，并不一定按照本公开示出和描述的顺序来执行相应方法的步骤，其方法所包括的步骤可以比本公开所描述的更多或更少。此外，本公开中所描述的单个步骤，在其它实施例中可能被分解为多个步骤进行描述；本公开中所描述的多个步骤，在其它实施例也可能被合并为单个步骤进行描述。

[100] 由以上技术方案可见，本公开实施例中，在解码得到重建图像块之后，重建图像块包括第一初始分量和第二初始分量，第二初始分量的分辨率是经过下采样的分辨率，第一初始分量的分辨率大于或者等于第二初始分量的分辨率，基于第一初始分量和第二初始分量生成第二初始分量对应的调整后分量，即基于第一初始分量辅助对第二初始分量进行调整，得到调整后分量，继而基于调整后分量确定第二初始分量对应的目标分量，从而能够提高解码性能，降低解码复杂度，降低计算复杂度，对资源需求比较少，对成本、延时敏感的设备也可以使用上述算法，提出低复杂度且高效的后处理网络模型框架，针对多种码率下的压缩缺陷恢复。

[101] 实施例 2：关于编码端（编码端也称为视频编码器）的处理过程，可以参见图 3 所示，图 3 只是编码端的处理过程的一个示例，对此编码端的处理过程不作限制。

[102] 编码端在得到当前图像块 x （当前图像块 x 可以为原始图像块 x ，即输入的图像块）之后，可以通过分析变换网络（即神经网络）对当前图像块 x 进行分析变换，得到当前图像块 x 对应的图像特征 y 。其中，通过分析变换网络对当前图像块 x 进行特征变换是指：将当前图像块 x 变换到 latent 域的图像特征 y ，从而方便后续所有过程在 latent

域上进行操作。

[103] 图像可以划分成 1 个图像块,也可以划分成多个图像块,若图像划分成 1 个图像块,则当前图像块 x 也可以为图像,即对于图像块的编解码过程也可以直接用于图像。

[104] 编码端在得到图像特征 y 之后,对图像特征 y 进行系数超参特征变换,得到系数超参特征 z ,比如说,可以将图像特征 y 输入给超参编码网络(即神经网络),由超参编码网络对图像特征 y 进行系数超参特征变换,得到系数超参特征 z 。其中,超参编码网络可以是已训练的神经网络,对此超参编码网络的训练过程不作限制,能够对图像特征 y 进行系数超参特征变换即可。其中,latent 域的图像特征 y 经过超参编码网络之后得到超先验 latent 信息 z 。

[105] 编码端在得到系数超参特征 z 之后,可以对系数超参特征 z 进行量化,得到系数超参特征 z 对应的超参量化特征,即图 3 中的 Q 操作为量化过程。在得到系数超参特征 z 对应的超参量化特征之后,对超参量化特征进行编码,得到当前图像块对应的 Bitstream#1(即第一码流),即图 3 中的 AE 操作表示编码过程,如熵编码过程。或者,编码端也可以直接对系数超参特征 z 进行编码,得到当前图像块对应的 Bitstream#1。其中,Bitstream#1 中携带的超参量化特征或者系数超参特征 z 主要用于获取均值和概率分布模型的参数。

[106] 在得到当前图像块对应的 Bitstream#1 之后,编码端可以将当前图像块对应的 Bitstream#1 发送给解码端,关于解码端针对当前图像块对应的 Bitstream#1 的处理过程,参见后续实施例。

[107] 编码端在得到当前图像块对应的 Bitstream#1 之后,还可以对 Bitstream#1 进行解码,得到超参量化特征,即图 3 中的 AD 表示解码过程,然后,对超参量化特征进行反量化,得到系数超参特征 z_hat ,系数超参特征 z_hat 与系数超参特征 z 可以相同或者不同,图 3 中的 IQ 操作为反量化过程。或者,编码端在得到当前图像块对应的 Bitstream#1 之后,还可以对 Bitstream#1 进行解码,得到系数超参特征 z_hat ,而不涉及系数超参特征 z_hat 的反量化过程。

[108] 针对 Bitstream#1 的编码过程,可以采用固定概率密度模型的编码方法,针对 Bitstream#1 的解码过程,可以采用固定概率密度模型的解码方法,对此编码和解码过程不做限制。

[109] 编码端在得到系数超参特征 z_hat 之后,可以基于当前图像块的系数超参特征 z_hat 和前面图像块的残差特征 y_hat (残差特征 y_hat 的确定过程参见后续实施例),进行基于上下文的预测,得到当前图像块对应的预测值 μ (即均值 μ),比如说,将系数超参特征 z_hat 和残差特征 y_hat 输入给均值预测网络,由均值预测网络基于系数超参特征 z_hat 和残差特征 y_hat 确定预测值 μ ,对此预测过程不作限制。其中,针对基于上下文的预测过程,输入包括系数超参特征 z_hat 和已解码的残差特征 y_hat ,两者联合输入获取更精准的预测值 μ ,预测值 μ 用于与原始特征作差获得残差和与解码的残差相加得到重建 y 。

[110] 需要注意的是,均值预测网络为可选的神经网络,即也可以没有均值预测网络,即不需要通过均值预测网络确定预测值 μ ,图 3 中的虚线框表示均值预测网络为可选。

[111] 编码端在得到图像特征 y 之后,可以基于图像特征 y 和预测值 μ 确定残差特征 r ,如将图像特征 y 与预测值 μ 的差值作为残差特征 r 。然后,对残差特征 r 进行特征处理,得到图像特征 s ,对此特征处理过程不做限制,可以是任意特征处理方式。在该情况下,需要部署均值预测网络,由均值预测网络提供预测值 μ 。或者,编码端在得到图像特征 y 之后,可以对图像特征 y 进行特征处理,得到图像特征 s ,对此特征处理

过程不做限制,可以是任意特征处理方式。在该情况下,不需要部署均值预测网络,通过虚线框表示残差过程为可选过程。

[112] 编码端在得到图像特征 s 之后,可以对图像特征 s 进行量化,得到图像特征 s 对应的图像量化特征,即图 3 中的 Q 操作为量化过程。在得到图像特征 s 对应的图像量化特征之后,编码端可以对该图像量化特征进行编码,得到当前图像块对应的 Bitstream#2 (即第二码流),即图 3 中的 AE 操作表示编码过程,如熵编码过程。或者,编码端也可以直接对图像特征 s 进行编码,得到当前图像块对应的 Bitstream#2,而不涉及图像特征 s 的量化过程。

[113] 在得到当前图像块对应的 Bitstream#2 之后,编码端可以将当前图像块对应的 Bitstream#2 发送给解码端,关于解码端针对当前图像块对应的 Bitstream#2 的处理过程,参见后续实施例。

[114] 编码端在得到当前图像块对应的 Bitstream#2 之后,还可以对 Bitstream#2 进行解码,得到图像量化特征,即图 3 中的 AD 表示解码过程,然后,编码端可以对图像量化特征进行反量化,得到图像特征 s' ,图像特征 s' 与图像特征 s 可以相同或者不同,图 3 中的 IQ 操作为反量化过程。或者,编码端在得到当前图像块对应的 Bitstream#2 之后,还可以对 Bitstream#2 进行解码,得到图像特征 s' ,而不涉及图像量化特征的反量化过程。

[115] 编码端在得到图像特征 s' 之后,可以对图像特征 s' 进行特征恢复(即特征处理的逆过程),对此特征恢复过程不做限制,可以是任意特征恢复方式,得到残差特征 r_hat ,残差特征 r_hat 与残差特征 r 可以相同或者不同。编码端得到残差特征 r_hat 后,基于残差特征 r_hat 和预测值 μ 确定图像特征 y_hat ,图像特征 y_hat 与图像特征 y 可以相同或不同,比如说,将残差特征 r_hat 与预测值 μ 的和作为图像特征 y_hat 。在该情况下,需要部署均值预测网络,由均值预测网络提供预测值 μ 。或者,编码端在得到图像特征 s' 之后,可以对图像特征 s' 进行特征恢复(即特征处理的逆过程),得到图像特征 y_hat ,图像特征 y_hat 与图像特征 y 可以相同或不同。在该情况下,不需要部署均值预测网络,通过虚线框表示残差过程为可选过程。

[116] 编码端在得到图像特征 y_hat 之后,可以对图像特征 y_hat 进行合成变换,得到当前图像块 x 对应的重建图像块 x_hat ,比如说,将图像特征 y_hat 输入给合成变换网络,由合成变换网络对图像特征 y_hat 进行合成变换,得到重建图像块 x_hat ,至此,完成图像重建过程。

[117] 在一种可能的实施方式中,编码端在对图像量化特征或者图像特征 s 进行编码,得到当前图像块对应的 Bitstream#2 时,编码端需要先确定概率分布模型,然后基于该概率分布模型对图像量化特征或者图像特征 s 进行编码。此外,编码端在对 Bitstream#2 进行解码时,也需要先确定概率分布模型,然后基于该概率分布模型对 Bitstream#2 进行解码。

[118] 为了得到概率分布模型,继续参见图 3 所示,编码端在得到系数超参特征 z_hat 之后,可以对系数超参特征 z_hat 进行系数超参特征反变换,得到概率分布参数 p ,比如说,将系数超参特征 z_hat 输入给概率超参解码网络,由概率超参解码网络对系数超参特征 z_hat 进行系数超参特征反变换,得到概率分布参数 p ,在得到概率分布参数 p 之后,可以基于概率分布参数 p 生成概率分布模型。其中,概率超参解码网络可以是已训练的神经网络,对此概率超参解码网络的训练过程不作限制,能够对系数超参特征 z_hat 进行系数超参特征反变换即可。

[119] 在一种可能的实施方式中,上述编码端的处理过程,可以由深度学习模型或者

神经网络模型执行,从而实现端到端的图像压缩和编码过程,对此编码过程不作限制。

[120] 实施例3:关于解码端(解码端也称为视频解码器)的处理过程,可以参见图4所示,图4只是解码端的处理过程的一个示例,对此解码端的处理过程不作限制。

[121] 解码端在得到当前图像块对应的 Bitstream#1 之后,还可以对 Bitstream#1 进行解码,得到超参量化特征,即图4中的 AD 表示解码过程,然后,对超参量化特征进行反量化,得到系数超参特征 $\hat{z}$, 系数超参特征 $\hat{z}$ 与系数超参特征 z 可以相同或者不同,图4中的 IQ 操作为反量化过程。或者,解码端在得到当前图像块对应的 Bitstream#1 之后,还可以对 Bitstream#1 进行解码,得到系数超参特征 $\hat{z}$, 而不涉及系数超参特征 $\hat{z}$ 的反量化过程。

[122] 针对 Bitstream#1 的解码过程,可以采用固定概率密度模型的解码方法,对此不做限制。

[123] 图像可以划分成1个图像块,也可以划分成多个图像块,若图像划分成1个图像块,则当前图像块 x 也可以为图像,即对于图像块的解码过程也可以直接用于图像。

[124] 解码端在得到系数超参特征 $\hat{z}$ 之后,可以基于当前图像块的系数超参特征 $\hat{z}$ 和前面图像块的残差特征 $\hat{y}$ (残差特征 $\hat{y}$ 的确定过程参见后续实施例),进行基于上下文的预测,得到当前图像块对应的预测值 μ (即均值 μ),比如说,将系数超参特征 $\hat{z}$ 和残差特征 $\hat{y}$ 输入给均值预测网络,由均值预测网络基于系数超参特征 $\hat{z}$ 和残差特征 $\hat{y}$ 确定预测值 μ ,对此预测过程不作限制。其中,针对基于上下文的预测过程,输入包括系数超参特征 $\hat{z}$ 和已解码的残差特征 $\hat{y}$,两者联合输入获取更精准的预测值 μ 。

[125] 需要注意的是,均值预测网络为可选的神经网络,即也可以没有均值预测网络,即不需要通过均值预测网络确定预测值 μ ,图4中的虚线框表示均值预测网络为可选。

[126] 解码端在得到当前图像块对应的 Bitstream#2 之后,还可以对 Bitstream#2 进行解码,得到图像量化特征,即图4中的 AD 表示解码过程,然后,解码端可以对图像量化特征进行反量化,得到图像特征 s' , 图像特征 s' 与图像特征 s 可以相同或者不同,图4中的 IQ 操作为反量化过程。或者,解码端在得到当前图像块对应的 Bitstream#2 之后,还可以对 Bitstream#2 进行解码,得到图像特征 s' , 而不涉及图像量化特征的反量化过程。

[127] 解码端在得到图像特征 s' 之后,可以对图像特征 s' 进行特征恢复(即特征处理的逆过程),得到残差特征 $\hat{r}$, 残差特征 $\hat{r}$ 与残差特征 r 相同或者不同。解码端在得到残差特征 $\hat{r}$ 之后,基于残差特征 $\hat{r}$ 和预测值 μ 确定图像特征 $\hat{y}$, 图像特征 $\hat{y}$ 与图像特征 y 相同或不同,如将残差特征 $\hat{r}$ 与预测值 μ 的和作为图像特征 $\hat{y}$ 。在该情况下,需要部署均值预测网络,由均值预测网络提供预测值 μ 。或者,解码端在得到图像特征 s' 之后,可以对图像特征 s' 进行特征恢复,得到图像特征 $\hat{y}$, 图像特征 $\hat{y}$ 与图像特征 y 可以相同或不同。在该情况下,不需要部署均值预测网络,通过虚线框表示残差过程为可选过程。

[128] 解码端在得到图像特征 $\hat{y}$ 之后,可以对图像特征 $\hat{y}$ 进行合成变换,得到当前图像块 x 对应的重建图像块 $\hat{x}$, 比如说,将图像特征 $\hat{y}$ 输入给合成变换网络,由合成变换网络对图像特征 $\hat{y}$ 进行合成变换,得到重建图像块 $\hat{x}$,至此,完成图像重建过程。

[129] 在一种可能的实施方式中,解码端在对 Bitstream#2 进行解码时,需要先确定概率分布模型,然后基于该概率分布模型对 Bitstream#2 进行解码。为了得到概率分布模

型,继续参见图4所示,解码端在得到系数超参特征 z_{hat} 之后,可以对系数超参特征 z_{hat} 进行系数超参特征反变换,得到概率分布参数 p ,比如说,将系数超参特征 z_{hat} 输入给概率超参解码网络,由概率超参解码网络对系数超参特征 z_{hat} 进行系数超参特征反变换,得到概率分布参数 p ,在得到概率分布参数 p 之后,可以基于概率分布参数 p 生成概率分布模型。其中,概率超参解码网络可以是已训练的神经网络,对此概率超参解码网络的训练过程不作限制,能够对系数超参特征 z_{hat} 进行系数超参特征反变换,得到概率分布参数 p 即可。

[130] 在一种可能的实施方式中,上述解码端的处理过程,可以由深度学习模型或者神经网络模型执行,从而实现端到端的图像压缩和编码过程,对此解码过程不作限制。

[131] 实施例4:参见图5A所示,为基于深度学习的端到端图像压缩的结构示意图,在编码端,图像会被转换为YUV色彩空间,并对UV信号进行二分之一采样,然后Y信号和UV信号被分别压缩编码,将Y信号码流和UV信号码流发送给解码端。在解码端,对Y信号码流进行解码重构,得到重构后的Y信号,对UV信号码流进行解码重构,得到重构后的UV信号。由于UV信号是进行二分之一采样后进行压缩编码,即UV信号的分辨率减半,因此,重构后的UV信号的分辨率减半,即重构后的Y信号的分辨率为 $H*W$,而重构后的UV信号的分辨率为 $H/2*W/2$,即重构后的UV信号的分辨率是重构后的Y信号的分辨率的一半。

[132] 由于重构后的UV信号的分辨率是重构后的Y信号的分辨率的一半,因此,在后处理过程中,还可以对UV信号的分辨率进行恢复,即将UV信号的分辨率恢复为 $H*W$ 。在对UV信号的分辨率进行恢复时,该分辨率恢复过程的计算复杂度较高,且对资源的需求比较大,一些对成本、延时敏感的设备无法对UV色度信号的分辨率进行恢复。

[133] 针对上述发现,本公开实施例中,在端到端的图像压缩领域中,提出一种低复杂度且高效的后处理方法,在后处理过程中,能够基于Y信号对UV信号进行增强,该方法复杂度较低且性能较高,能够提高解码性能,降低解码复杂度,降低计算复杂度,对资源的需求比较少,对成本、延时敏感的设备也可以使用上述算法,可以针对多种码率下的压缩缺陷恢复。

[134] 本公开实施例中,解码端在接收到当前图像块对应的码流之后,可以对当前图像块对应的码流进行解码得到重建图像块,比如说,解码端可以采用实施例3的处理流程,对当前图像块对应的码流进行解码得到重建图像块,对此重建图像块的解码过程不作限制。

[135] 在得到重建图像块之后,若重建图像块为YUV格式的重建图像块,则可以基于亮度分量(即Y分量)对色度U分量(即U分量)进行辅助增强,也可以基于Y分量对色度V分量(即V分量)进行辅助增强,还可以基于Y分量同时对U分量和V分量进行辅助增强。若重建图像块为RGB格式的重建图像块,则可以基于G分量对R分量进行辅助增强,也可以基于G分量对B分量进行辅助增强,还可以基于G分量同时对R分量和B分量进行辅助增强。为了方便描述,本实施例中,以YUV格式的重建图像块为例进行说明,因此,重建图像块可以包括Y分量、U分量和V分量,Y分量的分辨率可以大于U分量的分辨率,如U分量的分辨率是未经过下采样的分辨率,Y分量的分辨率可以是原始分辨率,也可以是经过下采样的分辨率,但是Y分量的分辨率大于U分量的分辨率。Y分量的分辨率可以大于V分量的分辨率,如V分量的分辨率是未经过下采样的分辨率,Y分量的分辨率可以是原始分辨率,也可以是经过下采样的分辨率,但是Y分量的分辨率大于V分量的分辨率。比如说,假设Y分量的分辨率为 $H*W$,U分量的分辨率为 $H/2*W/2$,V分量的分辨率为 $H/2*W/2$ 。

[136] 参见图 5B 所示, 为基于深度学习的后处理的结构示意图, 解码端可以对当前图像块对应的码流进行解码, 得到重建图像块, 若重建图像块为 YUV 格式的重建图像块, 则重建图像块可以包括 Y 分量、U 分量和 V 分量, 将 Y 分量记为 Y 初始分量 (即上述实施例的第一初始分量), 将 U 分量记为 U 初始分量 (即上述实施例的第二初始分量), 将 V 分量记为 V 初始分量 (即上述实施例的第二初始分量)。基于此, 可以基于 Y 初始分量对 U 初始分量进行辅助增强, 也可以基于 Y 初始分量对 V 初始分量进行辅助增强, 还可以基于 Y 初始分量对 U 初始分量和 V 初始分量进行辅助增强。其中, Y 初始分量的分辨率可以大于 U 初始分量的分辨率, Y 初始分量的分辨率可以大于 V 初始分量的分辨率。比如说, 参见图 5B 所示, Y 初始分量的分辨率为 $H*W$, U 初始分量的分辨率为 $H/2*W/2$, V 初始分量的分辨率为 $H/2*W/2$ 。

[137] 本实施例中, 参见图 5B 所示, 涉及预处理模块, 预处理模块为可选模块, 在解码得到 Y 初始分量之后, 若部署预处理模块, 则可以通过预处理模块对 Y 初始分量进行预处理, 得到预处理后的 Y 初始分量, 并将预处理后的 Y 初始分量输入给 Y 辅助 UV 模块和 YUV 信号增强模块。若未部署预处理模块, 则直接将 Y 初始分量输入给 Y 辅助 UV 模块和 YUV 信号增强模块。在后续实施例中, Y 辅助 UV 模块和 YUV 信号增强模块得到的 Y 初始分量, 可以为预处理后的 Y 初始分量, 也可以是解码得到的原始 Y 初始分量, 对此不作限制。

[138] 由于 YUV 三种分量之间存在着一定的相关性, 虽然编码端对 Y 分量的压缩损失较对 UV 分量的压缩损失更小, 但是, 也可以对 Y 分量做一定增强, 以便更好地增强 UV 分量, 因此, 可以通过预处理模块对 Y 初始分量进行预处理, 从而对 Y 初始分量进行特征增强。

[139] 本实施例中, 参见图 5B 所示, 涉及 Y 辅助 UV 模块, 在解码得到 Y 初始分量、U 初始分量和 V 初始分量之后, U 初始分量和 V 初始分量的损失较多, 而 Y 初始分量保留了相对较多的图像细节信息, 且 U 初始分量和 V 初始分量与 Y 初始分量存在着一定的相关性, 因此, 充分利用 Y 初始分量的信息可以有助于提高 U 初始分量和 V 初始分量的重建质量。

[140] 基于此, Y 辅助 UV 模块可以利用 Y 初始分量的信息辅助提高 U 初始分量的重建质量, 也可以利用 Y 初始分量的信息辅助提高 V 初始分量的重建质量, 还可以利用 Y 初始分量的信息辅助提高 U 初始分量的重建质量和 V 初始分量的重建质量。

[141] 本实施例中, 参见图 5B 所示, 涉及分辨率变换模块, 由于 U 初始分量的分辨率小于 Y 初始分量的分辨率, 如 U 初始分量的分辨率是 2 倍降采样后的分辨率, U 初始分量的分辨率是原始信号分辨率的一半, 如 $H/2*W/2$, 因此, 分辨率变换模块对 U 初始分量的分辨率进行上采样, 恢复出具有原始信号分辨率的 U 分量, 即对 U 初始分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 U 分量。由于 V 初始分量的分辨率小于 Y 初始分量的分辨率, 如 V 初始分量的分辨率是 2 倍降采样后的分辨率, V 初始分量的分辨率是原始信号分辨率的一半, 如 $H/2*W/2$, 因此, 分辨率变换模块对 V 初始分量的分辨率进行上采样, 恢复出具有原始信号分辨率的 V 分量, 即对 V 初始分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 V 分量。

[142] 分辨率变换模块的位置可以是位置 1, 即分辨率变换模块对 U 初始分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 U 分量, 将分辨率为 $H*W$ 的 U 分量输入给 Y 辅助 UV 模块, 分辨率变换模块对 V 初始分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 V 分量, 将分辨率为 $H*W$ 的 V 分量输入给 Y 辅助 UV 模块。或者, 分辨率变换模块的位置可以是位置 2, 即分辨率变换模块对 Y 辅助 UV 模块输出的 U 分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 U 分量, 将分辨率为 $H*W$ 的 U 分量输入给 YUV 信号

增强模块,分辨率变换模块对Y辅助UV模块输出的V分量的分辨率进行上采样,得到分辨率为 $H*W$ 的V分量,将分辨率为 $H*W$ 的V分量输入给YUV信号增强模块。或,分辨率变换模块的位置可以是位置3,即分辨率变换模块对YUV信号增强模块输出的U分量的分辨率进行上采样,得到分辨率为 $H*W$ 的U分量,最终输出这个 $H*W$ 的U分量,分辨率变换模块对YUV信号增强模块输出的V分量的分辨率进行上采样,得到分辨率为 $H*W$ 的V分量,最终输出这个 $H*W$ 的V分量。

[143] 对于分辨率变换模块,一方面,分辨率变换模块能够适当降低特征图的分辨率,从而可以有效降低网络的计算复杂度。另一方面,在JPEG-AI框架中,分辨率变换模块用于对重构的UV分量的分辨率进行上采样,从而恢复出具有与原始信号分辨率相同的重构U/V信号。

[144] 本实施例中,参见图5B所示,涉及YUV信号增强模块,在图像编码压缩过程中,除了会降低UV信号的分辨率,压缩算法以及卷积过程都会对YUV信号造成额外的信息丢失,因此,可以通过YUV信号增强模块对Y分量进行信号增强,使得重构出的Y分量接近压缩前的原始信号,以提升主观质量,可以通过YUV信号增强模块对U分量进行信号增强,使得重构出的U分量接近压缩前的原始信号,以提升主观质量,可以通过YUV信号增强模块对V分量进行信号增强,使得重构出的V分量接近压缩前的原始信号,以提升主观质量。

[145] 示例性的,参见图5B所示,可以将三条网络分支(三条网络分支分别处理Y分量、U分量、V分量)合并为一条网络分支,即使用单一网络同时处理Y分量、U分量和V分量,同时输出重建的Y分量、U分量和V分量,从而降低网络计算复杂度。

[146] 实施例5:在实施例4中,Y辅助UV模块可以利用Y初始分量的信息辅助提高U初始分量和/或V初始分量的重建质量,比如说,基于Y初始分量和U初始分量生成U初始分量对应的调整后分量,和/或,基于Y初始分量和V初始分量生成V初始分量对应的调整后分量。其中,U初始分量对应的调整后分量的重建质量可以优于U初始分量的重建质量,从而提升U初始分量的重建质量,U初始分量对应的调整后分量的重建质量也可能等于或者低于U初始分量的重建质量,对此不作限制。V初始分量对应的调整后分量的重建质量可以优于V初始分量的重建质量,从而提升V初始分量的重建质量,V初始分量对应的调整后分量的重建质量也可能等于或者低于V初始分量的重建质量,对此不作限制。

[147] 在一种可能的实施方式中,Y辅助UV模块可以获取Y初始分量对应的第一图像特征,第一图像特征可以是未经过神经网络的图像特征,如第一图像特征可以包括但不限于以下至少一种:纹理特征、主观特征、频域特征、或直方图特征。Y辅助UV模块可以获取U初始分量对应的第二图像特征,第二图像特征可以是未经过神经网络的图像特征,如第二图像特征可以包括但不限于以下至少一种:纹理特征、主观特征、频域特征、或直方图特征。Y辅助UV模块可以基于该第一图像特征和该第二图像特征生成调整后分量。比如说,可以基于Y初始分量对应的纹理特征和U初始分量对应的纹理特征生成纹理融合特征,使用纹理融合特征替换U初始分量对应的纹理特征,得到U初始分量对应的调整后分量。又例如,可以基于Y初始分量对应的主观特征和U初始分量对应的主观特征生成主观融合特征,使用主观融合特征替换U初始分量对应的主观特征,得到U初始分量对应的调整后分量。又例如,可以基于Y初始分量对应的频域特征和U初始分量对应的频域特征生成频域融合特征,使用频域融合特征替换U初始分量对应的频域特征,得到U初始分量对应的调整后分量。又例如,可以基于Y初始分量对应的直方图特征和U初始分量对应的直方图特征生成直方图融合特征,使用直方图融合特征替换U初始分量对应的直方图特征,得到U初始分量对应的调整后分量。

又例如,可以基于 Y 初始分量对应的纹理特征和 U 初始分量对应的纹理特征生成纹理融合特征,基于 Y 初始分量对应的频域特征和 U 初始分量对应的频域特征生成频域融合特征,使用纹理融合特征替换 U 初始分量对应的纹理特征,使用频域融合特征替换 U 初始分量对应的频域特征,得到 U 初始分量对应的调整后分量。上述只是几个示例,对此不作限制。

[148] Y 辅助 UV 模块可以获取 Y 初始分量对应的第一图像特征,第一图像特征可以是未经过神经网络的图像特征,如第一图像特征包括但不限于以下至少一种:纹理特征、主观特征、频域特征、或直方图特征。Y 辅助 UV 模块可以获取 V 初始分量对应的第二图像特征,第二图像特征可以是未经过神经网络的图像特征,如第二图像特征包括但不限于以下至少一种:纹理特征、主观特征、频域特征、或直方图特征。Y 辅助 UV 模块可以基于该第一图像特征和该第二图像特征生成 V 初始分量对应的调整后分量,生成方式参见 U 初始分量的处理过程。

[149] 在另一种可能的实施方式中, Y 辅助 UV 模块可以获取 Y 初始分量对应的第一图像特征,第一图像特征可以是经过神经网络的图像特征,即由神经网络输出的图像特征,如第一图像特征可以包括但不限于第一特征图、权重系数图等。Y 辅助 UV 模块可以获取 U 初始分量对应的第二图像特征,第二图像特征可以是经过神经网络的图像特征,即由神经网络输出的图像特征,如第二图像特征可以包括但不限于第二特征图等。Y 辅助 UV 模块可以基于该第一图像特征和该第二图像特征生成 U 初始分量对应的调整后分量。比如说,可以基于 Y 初始分量对应的第一特征图和 U 初始分量对应的第二特征图生成 U 初始分量对应的调整后分量。又例如,可以基于 Y 初始分量对应的权重系数图和 U 初始分量对应的第二特征图生成 U 初始分量对应的调整后分量。上述只是几个示例,对此不作限制。

[150] Y 辅助 UV 模块可以获取 Y 初始分量对应的第一图像特征,第一图像特征可以是经过神经网络的图像特征,即由神经网络输出的图像特征,如第一图像特征可以包括但不限于第一特征图、权重系数图等。Y 辅助 UV 模块可以获取 V 初始分量对应的第二图像特征,第二图像特征可以是经过神经网络的图像特征,即由神经网络输出的图像特征,如第二图像特征可以包括但不限于第二特征图等。Y 辅助 UV 模块可以基于该第一图像特征和该第二图像特征生成 V 初始分量对应的调整后分量,生成方式参见 U 初始分量的处理过程。

[151] 实施例 6: 为了使 UV 分量能够充分利用 Y 分量的信息,在后处理网络的输入阶段,对 Y 分量进行卷积以得到具有多个通道的特征图 (Feature Map), 这些特征图包含 Y 分量不同类型的特征,将这些不同类型的特征同 UV 分量卷积得到的特征图相加 (Add) 或拼叠 (Concat), 以便后续的神经网络可以学习到 Y 分量的多种特征,从而帮助 UV 分量提高重建质量。

[152] 比如说,参见图 6A 所示,为后处理网络的结构示意图, Y 辅助 UV 模块在得到 Y 初始分量、U 初始分量和 V 初始分量之后,可以将 Y 初始分量输入给第一神经网络 (如 CNN1), 得到第一特征图, 第一特征图也可以称为 Y 特征图 (Y Feature Map)。可以将 U 初始分量输入给第二神经网络 (如 CNN2), 得到 U 初始分量对应的第二特征图, 第二特征图也可以称为 U 特征图 (U Feature Map)。可以将 V 初始分量输入给第二神经网络 (如 CNN2), 得到 V 初始分量对应的第二特征图, 第二特征图也可以称为 V 特征图 (V Feature Map)。

[153] 在得到第一特征图和 U 初始分量对应的第二特征图之后,可以基于第一特征图和该第二特征图生成 U 初始分量对应的调整后分量。比如说,对该第一特征图和该第二特征图进行相加操作,图 6A 中的 $\oplus$ 表示特征图的相加操作,将相加操作后的特征图输入

给第三神经网络（如 CNN3），得到 U 初始分量对应的调整后分量。或者，对该第一特征图和该第二特征图进行拼叠操作，图 6A 中的 $\oplus$ 表示特征图的拼叠操作，将拼叠操作后的特征图输入给第三神经网络（如 CNN3），得到 U 初始分量对应的调整后分量。在得到第一特征图和 V 初始分量对应的第二特征图之后，可以基于第一特征图和第二特征图生成 V 初始分量对应的调整后分量。比如说，对该第一特征图和该第二特征图进行相加操作，将相加操作后的特征图输入给第三神经网络，得到 V 初始分量对应的调整后分量。或者，对该第一特征图和该第二特征图进行拼叠操作，将拼叠操作后的特征图输入给第三神经网络，得到 V 初始分量对应的调整后分量。

[154] 对第一特征图和第二特征图进行拼叠操作是指，沿着通道维度对第一特征图和第二特征图进行拼叠操作。

[155] 示例性的，为了能够正确实现上述操作，第二神经网络的卷积核个数与第一神经网络的卷积核个数可以相同，如 CNN1 和 CNN2 具有相同的卷积核个数。图 6A 所示的处理过程还可以表示为： $U_{\text{rec}}/V_{\text{rec}} = f_{\text{CNN3}}(f_{\text{CNN1}}(Y) \oplus f_{\text{CNN2}}(U/V))$ ， f_{CNN} 表示卷积神经网络，“ $\oplus$ ”表示特征图的相加操作或拼叠操作。Y 表示 Y 初始分量， $f_{\text{CNN1}}(Y)$ 表示第一特征图，U 表示 U 初始分量， $f_{\text{CNN2}}(U)$ 表示第二特征图，V 表示 V 初始分量， $f_{\text{CNN2}}(V)$ 表示第二特征图， U_{rec} 表示 U 初始分量对应的调整后分量， V_{rec} 表示 V 初始分量对应的调整后分量。

[156] 实施例 7：为了能够利用 Y 分量的每个特征图的信息，可以引入引导滤波，即通过 Y 分量产生的特征指导 UV 分量产生表征能力更强的特征图。考虑通过注意力的方式将 Y 分量的特征图，作为引导变量去加权 UV 特征图中的像素值，从而强化 UV 分量中的重要特征，并抑制 UV 分量中的一般特征，从而实现 Y 分量与 UV 分量的特征高效转换与融合。

[157] 比如说，参见图 6B 所示，为后处理网络的结构示意图，Y 辅助 UV 模块在得到 Y 初始分量、U 初始分量和 V 初始分量之后，可以将 Y 初始分量输入给第一神经网络（如 CNN1），得到第一特征图，第一特征图也可以称为 Y 特征图（Y Feature Map）。可以将 U 初始分量输入给第二神经网络（如 CNN2），得到 U 初始分量对应的第二特征图，第二特征图也可以称为 U 特征图（U Feature Map）。可以将 V 初始分量输入给第二神经网络（如 CNN2），得到 V 初始分量对应的第二特征图，第二特征图也可以称为 V 特征图（V Feature Map）。

[158] 在得到第一特征图和 U 初始分量对应的第二特征图之后，还可以对第一特征图进行引导滤波，得到权重系数图，并基于该权重系数图和该第二特征图生成 U 初始分量对应的调整后分量。比如说，基于该权重系数图和该第二特征图进行操作，如相乘操作、相加操作、或拼叠操作的至少一种，得到输出特征图（Output Feature Map），如基于该权重系数图和该第二特征图进行相乘操作，得到输出特征图，或者，可以基于该权重系数图和该第二特征图进行相乘操作和相加操作，得到输出特征图，或者，可以基于该权重系数图和该第二特征图进行相乘操作、相加操作和拼叠操作，得到输出特征图。在得到输出特征图之后，可以将输出特征图输入给第三神经网络（如 CNN3），得到 U 初始分量对应的调整后分量。

[159] 在得到第一特征图和 V 初始分量对应的第二特征图之后，还可以对第一特征图进行引导滤波，得到权重系数图，并基于该权重系数图和该第二特征图生成 V 初始分量对应的调整后分量。比如说，基于该权重系数图和该第二特征图进行操作，如相乘操作、相加操作、或拼叠操作的至少一种，得到输出特征图（Output Feature Map），在得到输出特征图之后，可以将输出特征图输入给第三神经网络（如 CNN3），得到 V 初始分量对应的调整后分量。

[160] 示例性的，图 6B 所示的处理过程还可以表示为：

$$U_{\text{rec}}/V_{\text{rec}} = f_{\text{CNN3}} \left(f_G \left(f_{\text{CNN1}}(Y), f_{\text{CNN2}}(U/V) \right) \right)$$
 f_{CNN} 表示卷积神经网络， f_G 表示引导滤波，引导滤波将Y分量和UV分量的特征图作为输入，输出为经过引导加权后的融合特征图。Y表示Y初始分量， $f_{\text{CNN1}}(Y)$ 表示第一特征图，U表示U初始分量， $f_{\text{CNN2}}(U)$ 表示第二特征图，V表示V初始分量， $f_{\text{CNN2}}(V)$ 表示第二特征图， U_{rec} 表示U初始分量对应的调整后分量， V_{rec} 表示V初始分量对应的调整后分量。

[161] 在一种可能的实施方式中，引导滤波的实施方式可以参见图 6C 所示，可以对第一特征图（Y Feature Map）进行卷积操作，得到卷积后特征图（后续记为卷积后特征图 A），比如说，将第一特征图输入给 CNN 网络，由 CNN 网络对第一特征图进行卷积操作，得到卷积后特征图 A，然后，对卷积后特征图 A 进行权重映射，得到权重映射后的权重系数图。

[162] 在基于权重系数图和 U 初始分量对应的第二特征图生成 U 初始分量对应的调整后分量时，可以对该权重系数图和 U 初始分量对应的第二特征图（U Feature Map）进行相乘操作，得到相乘后特征图。然后，对相乘后特征图和卷积后特征图 A 进行相加操作，得到相加后特征图。然后，对相加后特征图和卷积后特征图 A 进行拼叠操作，得到输出特征图（Output Feature Map），并将输出特征图输入给第三神经网络（如 CNN3），得到 U 初始分量对应的调整后分量。

[163] 在基于权重系数图和 V 初始分量对应的第二特征图生成 V 初始分量对应的调整后分量时，可以对该权重系数图和 V 初始分量对应的第二特征图（V Feature Map）进行相乘操作，得到相乘后特征图。然后，对相乘后特征图和卷积后特征图 A 进行相加操作，得到相加后特征图。然后，对相加后特征图和卷积后特征图 A 进行拼叠操作，得到输出特征图（Output Feature Map），并将输出特征图输入给第三神经网络（如 CNN3），得到 V 初始分量对应的调整后分量。

[164] 参见图 6C 所示，在将 Y 分量的第一特征图经过若干卷积层之后，得到卷积后特征图 A，通过权重映射将卷积后特征图 A 映射为特定的权重因子，即权重系数图，将权重系数图与 UV 分量的第二特征图进行相乘得到 UV 分量的特征引导图，然后将卷积后特征图 A 与 UV 分量的特征引导图相加，最后与卷积后特征图 A 拼叠，输出融合特征图（Output Feature Map）。比如说，引导滤波过程表示为： $\text{Out} = \text{Concat} \left((U/V) * f_w(f_{\text{CNN}}(Y)) + f_{\text{CNN}}(Y), f_{\text{CNN}}(Y) \right)$ ， f_w 表示权重映射， $\text{Concat}(\cdot)$ 表示拼叠操作， $f_{\text{CNN}}(Y)$ 表示卷积后特征图 A，Out 为输出特征图。

[165] 在一种可能的实施方式中，在权重映射过程中，对卷积后特征图 A 进行权重映射，得到权重映射后的权重系数图，权重映射的实施方式可以参见图 6D 所示，图 6D 中示出了两种权重映射方式。在第一种权重映射方式中，对卷积后特征图 A 进行池化操作，得到池化操作后特征图。比如说，对尺寸为 $C*H*W$ 的卷积后特征图 A 进行池化操作（Pooling），得到尺寸为 $C*1*1$ 的池化操作后特征图，即通过“Pooling”的方式将特征图的分辨率降为 $1*1$ 。

[166] 然后，对池化操作后特征图进行全连接操作和 ReLU 激活操作，得到 ReLU 激活操作后特征图。比如说，对尺寸为 $C*1*1$ 的池化操作后特征图进行全连接操作（即 FC 操作）和 ReLU 激活操作（即 ReLU 操作），得到尺寸为 $C*1*1$ 的 ReLU 激活操作后特征图。对 ReLU 激活操作后特征图进行全连接操作和 Sigmoid 激活操作，得到 Sigmoid 激活操作后特征图。比如说，对尺寸为 $C*1*1$ 的 ReLU 激活操作后特征图进行全连接操作（即 FC 操作）和 Sigmoid 激活操作（即 Sigmoid 操作），得到尺寸为 $C*1*1$ 的 Sigmoid 激活操作后特征图。

[167] 然后, 基于卷积后特征图 A 和 Sigmoid 激活操作后特征图生成权重系数图, 例如, 卷积后特征图 A 和 Sigmoid 激活操作后特征图相乘得到权重系数图。比如说, 对尺寸为 $C*H*W$ 的卷积后特征图 A 和尺寸为 $C*1*1$ 的 Sigmoid 激活操作后特征图进行相乘操作, 得到尺寸为 $C*H*W$ 的权重系数图。显然, 在通过“Pooling”的方式将特征图的分辨率降为 $1*1$ 后, 经过若干全连接层, 最后通过 Sigmoid 激活函数得到原输入特征图中每个通道的权重因子, 这些权重因子将赋予原输入特征图通道不同的权重, 最后得到权重系数图 (也称为权重特征图)。

[168] 在第二种权重映射方式中, 可以对卷积后特征图 A 进行卷积操作, 得到卷积后特征图 B, 比如说, 将尺寸为 $C*H*W$ 的卷积后特征图 A 输入给 CNN 网络, 由 CNN 网络通过若干个卷积层对卷积后特征图 A 进行卷积操作, 得到尺寸为 $C*H*W$ 的卷积后特征图 B。然后, 对卷积后特征图 B 进行 Sigmoid 激活操作, 得到权重系数图。比如说, 采用 Sigmoid 激活函数对尺寸为 $C*H*W$ 的卷积后特征图 B 进行激活操作, 得到尺寸为 $C*H*W$ 的权重系数图。显然, 通过将原输入特征图经过若干卷积层后通过 Sigmoid 激活函数, 最后得到权重系数图。

[169] 第一种权重映射方式和第二种权重映射方式的区别在于: 第一种权重映射方式中, 给通道赋予不同的权重, 第二种权重映射方式中, 给每个通道特征图的每个像素点赋予不同权重。

[170] 实施例 8: 在实施例 6 和实施例 7 中, 均是在后处理网络的输入阶段进行 Y 分量的特征提取和信息融合, 与实施例 6 和实施例 7 不同的是, 在实施例 8 中, 将 Y 分量的特征提取和信息融合分布在后处理网络的各个阶段, 将不同阶段的 UV 分量的特征与 Y 分量的特征进行融合, 从而提高后处理网络对 UV 分量的增强能力。比如说, 参见图 6E 所示, 为后处理网络的结构示意图, Y 辅助 UV 模块在得到 Y 初始分量、U 初始分量和 V 初始分量之后, 将 Y 分量的特征提取和信息融合分布在后处理网络的各个阶段, f_B 为特征融合过程, 特征融合过程可以采用实施例 6 或者实施例 7 的实施方式, 通过融合 Y 分量与 UV 分量的信息而输出融合特征图, 再经过若干卷积层后, 又作为下一个特征融合过程的输入, 相应地, Y 分量也会通过若干卷积层后作为下一个特征融合过程的输入。在实施例 8 中, 会涉及多个特征融合过程, 从而将 Y 分量的特征图与网络各个阶段的 UV 分量的特征图进行融合。

[171] 在一种可能的实施方式中, 由于将 Y 分量的特征图与网络各个阶段的 UV 分量的特征图进行融合, 因此, 涉及多个第一特征图和多个第二特征图, 以 K 个第一特征图和 K+1 个第二特征图为例, K 可以为大于 1 的正整数, 基于此, 在得到 Y 初始分量和 U 初始分量后, 针对首个第一特征图和首个第二特征图, 将 Y 初始分量输入给神经网络得到首个第一特征图, 并将 U 初始分量输入给神经网络得到首个第二特征图。针对第 i 个第一特征图和第 i 个第二特征图, i 的取值范围是 2 到 K, 将第 i-1 个第一特征图输入给神经网络得到第 i 个第一特征图, 对第 i-1 个第一特征图和第 i-1 个第二特征图进行特征融合得到融合后特征, 并将融合后特征输入给神经网络得到第 i 个第二特征图。在得到最后一个第二特征图 (即第 K+1 个第二特征图) 之后, 可以基于最后一个第二特征图生成 U 初始分量对应的调整后分量。

[172] 例如, 以 K 是 3 为例, 将 Y 初始分量输入给神经网络 a1 得到第一特征图 b1, 即神经网络 a1 对 Y 初始分量进行若干卷积操作, 得到第一特征图 b1。将 U 初始分量输入给神经网络 c1 得到第二特征图 d1, 即神经网络 c1 对 U 初始分量进行若干卷积操作, 得到第二特征图 d1。

[173] 将第一特征图 b1 输入给神经网络 a2 得到第一特征图 b2, 即神经网络 a2 对第一特征图 b1 进行若干卷积操作, 得到第一特征图 b2。对第一特征图 b1 和第二特征图 d1

进行特征融合得到融合后特征,并将融合后特征输入给神经网络 c2 得到第二特征图 d2。

[174] 将第一特征图 b2 输入给神经网络 a3 得到第一特征图 b3,即神经网络 a3 对第一特征图 b2 进行若干卷积操作,得到第一特征图 b3。对第一特征图 b2 和第二特征图 d2 进行特征融合得到融合后特征,并将融合后特征输入给神经网络 c3 得到第二特征图 d3。

[175] 然后,对第一特征图 b3 和第二特征图 d3 进行特征融合得到融合后特征,并将融合后特征输入给神经网络 c4 得到第二特征图 d4。在得到第二特征图 d4 之后,可以基于第二特征图 d4 生成 U 初始分量对应的调整后分量,如将第二特征图 d4 作为 U 初始分量对应的调整后分量,也可以对第二特征图 d4 进行操作后得到 U 初始分量对应的调整后分量。

[176] 在上述过程中,对第一特征图和第二特征图进行特征融合得到融合后特征,可以包括但不限于:对该第一特征图和该第二特征图进行相加操作,得到融合后特征;或者,对该第一特征图和该第二特征图进行拼叠操作,得到融合后特征;或者,对该第一特征图进行引导滤波,得到第一特征图对应的权重系数图,并基于权重系数图和该第二特征图生成融合后特征。其中,关于特征融合的实现方式,可以参见实施例 6 和实施例 7,在此不再重复赘述。

[177] 在得到 Y 初始分量和 V 初始分量后,针对首个第一特征图和首个第二特征图,将 Y 初始分量输入给神经网络得到首个第一特征图,并将 V 初始分量输入给神经网络得到首个第二特征图。针对第 i 个第一特征图和第 i 个第二特征图,i 的取值范围是 2-K,将第 i-1 个第一特征图输入给神经网络得到第 i 个第一特征图,对第 i-1 个第一特征图和第 i-1 个第二特征图进行特征融合得到融合后特征,并将融合后特征输入给神经网络得到第 i 个第二特征图。在得到最后一个第二特征图之后,可以基于最后一个第二特征图生成 V 初始分量对应的调整后分量,V 初始分量对应的调整后分量的获取方式,可以参见 U 初始分量的处理过程。

[178] 实施例 9:在实施例 6、实施例 7 和实施例 8 中,均是对 Y 分量引导图的融合方式进行设计,与实施例 6、实施例 7 和实施例 8 不同的是,在实施例 9 中,将 Y 分量从多维度进行细致的特征提取,然后融合进后处理网络,从而提高网络对 UV 分量的增强能力。

[179] 参见图 6F 所示,为后处理网络的结构示意图,Y 辅助 UV 模块在得到 Y 初始分量、U 初始分量和 V 初始分量之后,先对 Y 初始分量进行多维度特征提取,比如说,从 Y 初始分量中提取 M 个维度的图像特征,M 为正整数,然后,对 M 个维度的图像特征进行拼叠,得到拼叠后的多维度特征。在得到多维度特征之后,可以将多维度特征输入给第一神经网络,得到第一特征图(Y Feature Map)。此外,Y 辅助 UV 模块还可以将 U 初始分量输入给第二神经网络(如 CNN2),得到 U 初始分量对应的第二特征图,第二特征图也可以称为 U 特征图(U Feature Map)。可以将 V 初始分量输入给第二神经网络(如 CNN2),得到 V 初始分量对应的第二特征图,第二特征图也可以称为 V 特征图(V Feature Map)。

[180] 在得到第一特征图和 U 初始分量对应的第二特征图之后,就可以对第一特征图和第二特征图进行特征融合,得到 U 初始分量对应的调整后分量,在得到第一特征图和 V 初始分量对应的第二特征图之后,就可以对第一特征图和第二特征图进行特征融合,得到 V 初始分量对应的调整后分量,关于该特征融合过程,可以参见实施例 6、实施例 7 和实施例 8。

[181] 示例性的,图 6F 所示的处理过程还可以表示为:

$$U_{\text{rec}}/V_{\text{rec}} = f_{\text{CNN2}}\left(f_G\left(f_A(Y), f_{\text{CNN1}}(U/V)\right)\right), f_G \text{ 表示特征融合过程}, f_A \text{ 表示 Y 分量的多维}$$

度特征提取过程，在多维特征提取过程中，将Y初始分量作为输入，输出为多种维度的多个特征图，每个分支代表一种维度的特征。

[182] 比如说，参见图6G所示，为多维特征提取过程的示意图，Y初始分量作为输入，每个分支特征提取结构用于提取Y初始分量的特征。比如说，将Y初始分量输入给分支1特征提取结构，由分支1特征提取结构提取Y初始分量的第1个维度的特征，将Y初始分量输入给分支2特征提取结构，由分支2特征提取结构提取Y初始分量的第2个维度的特征，以此类推，将Y初始分量输入给分支M特征提取结构，由分支M特征提取结构提取Y初始分量的第M个维度的特征。综上所述，可以从Y初始分量中提取M个维度的图像特征，对M个维度的图像特征进行拼叠，得到拼叠后的多维特征。在得到拼叠后的多维特征后，可以将多维特征作为第一特征图，也可以将多维特征输入给第一神经网络得到第一特征图。

[183] 在图6G中，示出了一种多维特征提取过程的示意图，首先将Y分量通过不同的特征提取通道获得各个维度上的特征信息，最后将这些特征信息concat到输出作为Y分量特征图，多维特征提取过程可以表示为：
$$\text{Out} = \text{Concat}(f_{\text{ch}-1}(Y), f_{\text{ch}-2}(Y), \dots, f_{\text{ch}-M}(Y))$$
，其中， $f_{\text{ch}-i}$ 表示第i种特征提取结构，用于提取第i个维度的特征，Concat(·)表示拼叠操作。

[184] 在一种可能的实施方式中，M个维度的图像特征可以包括但不限于以下至少一种：采用一个卷积核对Y初始分量进行卷积后的图像特征；采用两个卷积核对Y初始分量进行卷积级联后的图像特征；采用sobel算子对Y初始分量进行处理后的一阶空域特征；采用Laplacian算子对Y初始分量进行处理后的二阶空域特征；或对Y初始分量进行傅里叶变换后的频域特征。上述图像特征只是几个示例，本实施例中对此图像特征的类型不作限制。

[185] 参见图6H所示，为多维特征提取结构的示意图，分支1特征提取结构（即第一个分支）采用一个3*3的卷积获取特征信息，比如说，采用一个3*3的卷积核对Y初始分量进行卷积，得到卷积后的图像特征。分支2特征提取结构（即第二个分支）采用1*1和3*3卷积级联的方式获得通道膨胀压缩后的特征信息，比如说，采用1*1和3*3卷积核对Y初始分量进行卷积级联，得到卷积级联后的图像特征。分支3特征提取结构（即第三个分支）使用sobel算子获得一阶空域特征，比如说，采用sobel算子对Y初始分量进行处理，得到一阶空域特征。分支4特征提取结构（即第四个分支）使用Laplacian算子获得二阶空域特征，比如说，采用Laplacian算子对Y初始分量进行处理，得到二阶空域特征。分支5特征提取结构（即第五个分支）使用傅里叶变换获得频域特征，比如说，对Y初始分量进行傅里叶变换，得到频域特征。在得到上述五个维度的特征之后，就可以对这些特征进行拼叠得到多维特征。

[186] 实施例10：在实施例6-实施例9中，主要关注选取哪些Y分量特征以及如何将Y分量特征与UV分量特征进行融合，与实施例6-实施例9不同的是，在实施例10中，侧重点在如何强化Y分量的特征。比如说，图像的YUV分量在经过编码压缩后，Y分量的图像细节也存在一定损失，因此，还可以先对Y分量及Y分量的特征进行一定地增强。比如说，由于YUV三种分量之间存在着一定的相关性，虽然编码端对Y分量的压缩损失较对UV分量的压缩损失更小，但是，也可以对Y分量做一定增强，以便更好地增强UV分量，因此，可以通过预处理模块对Y初始分量进行预处理，从而对Y初始分量进行特征增强。

[187] 比如说，预处理模块在得到Y初始分量之后，可以先对Y初始分量进行边缘增强，得到边缘增强后的图像特征；然后，对边缘增强后的图像特征进行多尺度的特征提取，得到多尺度特征。在得到多尺度特征之后，可以将多尺度特征作为预处理后的Y初

始分量,将预处理后的Y初始分量输入给Y辅助UV模块,由Y辅助UV模块将该预处理后的Y初始分量输入给第一神经网络,得到第一特征图(Y Feature Map)。此外,Y辅助UV模块还可以将U初始分量输入给第二神经网络(如CNN2),得到U初始分量对应的第二特征图,第二特征图也可以称为U特征图(U Feature Map)。可以将V初始分量输入给第二神经网络(如CNN2),得到V初始分量对应的第二特征图,第二特征图也可以称为V特征图(V Feature Map)。

[188] 在得到第一特征图和U初始分量对应的第二特征图之后,就可以对第一特征图和第二特征图进行特征融合,得到U初始分量对应的调整后分量,在得到第一特征图和V初始分量对应的第二特征图之后,就可以对第一特征图和第二特征图进行特征融合,得到V初始分量对应的调整后分量,关于该特征融合过程,可以参见实施例6、实施例7和实施例8。

[189] 预处理模块对边缘增强后的图像特征进行多尺度的特征提取得到多尺度特征时,可以对边缘增强后的图像特征进行卷积操作,得到卷积后特征;对卷积后特征进行下采样操作,得到下采样后特征;对下采样后特征进行通道变换,得到通道变换后特征;对通道变换后特征进行上采样操作,得到上采样后特征;基于上采样后特征和通道变换后特征生成多尺度特征。

[190] 参见图6I所示,为后处理网络的结构示意图,列举了一种Y分量的多尺度增强方式,在下采样部分,从D1到D3,特征图的分辨率逐渐减小,并且通道数逐渐增加。在上采样部分,从U3到U1,特征图的分辨率逐渐增大,通道数维持不变。D3、D2、D1通过通道变换后分别与U3、U2、U1上采样后的特征图相加,得到经过多尺度增强后的多尺度特征。

[191] 首先,对Y初始分量进行边缘增强,得到边缘增强后的图像特征,比如说,对Y初始分量进行图像锐化增强操作,得到边缘增强后的图像特征,对此边缘增强方式不作限制。

[192] 以2次下采样操作和2次上采样操作为例,下采样操作的数量可以更多,上采样操作的数量可以更多,对此不作限制。在得到边缘增强后的图像特征之后,将边缘增强后的图像特征输出给CNN,得到尺度为 $C*H*W$ 的特征D1,对特征D1进行下采样操作,得到尺度为 $4C*H/2*W/2$ 的特征D2,对特征D2进行下采样操作,得到尺度为 $16C*H/4*W/4$ 的特征D3。

[193] 对特征D3进行通道变换,得到尺度为 $T*H/4*W/4$ 的特征U3,对特征U3进行上采样操作,对特征D2进行通道变换,对上采样操作后的特征U3和通道变换后的特征D2进行相加操作,得到尺度为 $T*H/2*W/2$ 的特征U2。对特征U2进行上采样操作,对特征D1进行通道变换,对上采样操作后的特征U2和通道变换后的特征D1进行相加操作,得到尺度为 $T*H*W$ 的特征U1。显然,特征U1为经过多尺度增强后的多尺度特征,即预处理后的Y初始分量,预处理模块会输出这个预处理后的Y初始分量。通过对Y分量进行多尺度的特征提取,最后的输出的第一特征图综合了不同尺度下的特征信息,使之有助于增强UV分量。

[194] 实施例11:在实施例4中,涉及分辨率变换模块,分辨率变换模块用于对U分量的分辨率进行上采样,恢复出具有原始信号分辨率的U分量,如得到分辨率为 $H*W$ 的U分量。分辨率变换模块用于对V初始分量的分辨率进行上采样,恢复出具有原始信号分辨率的V分量,如得到分辨率为 $H*W$ 的V分量。比如说,在JPEG-AI框架中,原始的UV分量会被2倍降采样处理,然后经由编码端压缩编码,因此,解码端解码重构出的UV分量分辨率为原始信号分辨率的一半。在后处理网络中,存在对UV分量进行上采样的步骤,从而恢复出具有与原始信号分辨率相同的重构UV分量。示例性的,

分辨率变换模块对 U 分量和/或 V 分量的分辨率进行上采样时, 上采样的方法可以包括但不限于: 插值采样、Pixel-shuffle 上采样、反卷积 DeConv 等, 上述只是几个示例, 本实施例中对此上采样的方法不作限制。

[195] 示例性的, 由于对 UV 分量的分辨率进行上采样后, 会影响网络模型的计算复杂度, 即分辨率增加导致计算复杂度增加, 分辨率变换模块的位置会影响网络模型的计算复杂度, 因此, 可以涉及分辨率变换模块的位置, 以减少网络模型的计算复杂度。

[196] 情况 1: 参见图 5B 所示, 分辨率变换模块的位置可以是位置 1, 即分辨率变换模块对 U 初始分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 U 分量, 将分辨率为 $H*W$ 的 U 分量输入给 Y 辅助 UV 模块, 分辨率变换模块对 V 初始分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 V 分量, 将分辨率为 $H*W$ 的 V 分量输入给 Y 辅助 UV 模块。在此基础上, 针对实施例 5-实施例 10, U 初始分量均是上采样后的 U 分量, V 初始分量均是上采样后的 V 分量, 上采样后的 U 分量的分辨率可以等于 Y 初始分量的分辨率, 上采样后的 V 分量的分辨率可以等于 Y 初始分量的分辨率, 这样, 基于 Y 初始分量和上采样后的 U 分量执行实施例 5-实施例 10, 基于 Y 初始分量和上采样后的 V 分量执行实施例 5-实施例 10。

[197] 综上所述可以看出, 在情况 1 中, 可以在网络的输入端进行上采样, 参见图 7A 所示, 为网络输入端进行上采样的示意图, 也就是说, 在网络的输入端, 可以对 U 初始分量进行上采样, 得到上采样后的 U 分量, 如分辨率为 $H*W$ 的 U 分量, 在网络的输入端, 可以对 V 初始分量进行上采样, 得到上采样后的 V 分量, 如分辨率为 $H*W$ 的 V 分量。

[198] 情况 2: 参见图 5B 所示, 分辨率变换模块的位置可以是位置 2, 即分辨率变换模块对 Y 辅助 UV 模块输出的 U 分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 U 分量, 将分辨率为 $H*W$ 的 U 分量输入给 YUV 信号增强模块, 分辨率变换模块对 Y 辅助 UV 模块输出的 V 分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 V 分量, 将分辨率为 $H*W$ 的 V 分量输入给 YUV 信号增强模块。在此基础上, 针对实施例 5-实施例 10, U 初始分量均是上采样前的 U 分量, V 初始分量均是上采样前的 V 分量, 上采样前的 U 分量的分辨率可以小于 Y 初始分量的分辨率, 上采样前的 V 分量的分辨率可以小于 Y 初始分量的分辨率, 这样, 基于 Y 初始分量和上采样前的 U 分量执行实施例 5-实施例 10, 基于 Y 初始分量和上采样前的 V 分量执行实施例 5-实施例 10。在基于实施例 5-实施例 10 得到 U 分量/V 分量对应的调整后分量之后, 还可以对调整后分量进行上采样, 得到上采样后的调整后分量, 将上采样后的调整后分量输入给 YUV 信号增强模块, 上采样后的调整后分量的分辨率等于 Y 初始分量的分辨率。

[199] 综上所述可以看出, 在情况 2 中, 可以在网络逐层渐进上采样, 参见图 7B 所示, 为网络逐层渐进上采样的示意图, 也就是说, 在多个网络层, 可以对 U 初始分量进行上采样, 得到上采样后的 U 分量, 上采样后的 U 分量的分辨率可以等于 Y 初始分量的分辨率, 如分辨率为 $H*W$ 的 U 分量, 在多个网络层, 可以对 V 初始分量进行上采样, 得到上采样后的 V 分量, 上采样后的 V 分量的分辨率可以等于 Y 初始分量的分辨率, 如分辨率为 $H*W$ 的 V 分量。

[200] 情况 3: 参见图 5B 所示, 分辨率变换模块的位置可以是位置 3, 即分辨率变换模块对 YUV 信号增强模块输出的 U 分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 U 分量, 并最终输出这个 $H*W$ 的 U 分量, 分辨率变换模块对 YUV 信号增强模块输出的 V 分量的分辨率进行上采样, 得到分辨率为 $H*W$ 的 V 分量, 并最终输出这个 $H*W$ 的 V 分量。在此基础上, 针对实施例 5-实施例 10, U 初始分量均是上采样前的 U 分量, V 初始分量均是上采样前的 V 分量, 上采样前的 U 分量的分辨率小于 Y 初始分量的分辨率, 上采样前的 V 分量的分辨率小于 Y 初始分量的分辨率, 这样, 基于 Y 初始分量

和上采样前的 U 分量执行实施例 5-实施例 10, 基于 Y 初始分量和上采样前的 V 分量执行实施例 5-实施例 10。在基于实施例 5-实施例 10 得到 U 分量/V 分量对应的调整后分量后, 将调整后分量输入给 YUV 信号增强模块, 且调整后分量是上采样前的 U 分量/V 分量, 上采样前的 U 分量/V 分量小于 Y 初始分量的分辨率, 这样, YUV 信号增强模块基于上采样前的 U 分量/V 分量进行信号增强, 得到信号增强后的 U 分量/V 分量。得到信号增强后的 U 分量/V 分量后, 对 U 分量/V 分量进行上采样, 得到上采样后的 U 分量/V 分量, 上采样后的 U 分量/V 分量的分辨率等于 Y 初始分量的分辨率。

[201] 综上可以看出, 在情况 3 中, 可以在网络的输出端进行上采样, 参见图 7C 所示, 为在网络的输出端进行上采样的示意图, 也就是说, 在网络的输出端, 可以对 U 分量进行上采样, 得到上采样后的 U 分量, 上采样后的 U 分量的分辨率可以等于 Y 初始分量的分辨率, 如分辨率为 $H*W$ 的 U 分量, 在网络的输出端, 可以对 V 分量进行上采样, 得到上采样后的 V 分量, 上采样后的 V 分量的分辨率可以等于 Y 初始分量的分辨率, 如分辨率为 $H*W$ 的 V 分量。

[202] 实施例 12: 在实施例 4 中, 涉及分辨率变换模块, 第一方面, 分辨率变换模块可以通过使用无信息损失的分辨率变换, 适当降低特征图的分辨率, 从而可以有效降低网络的计算复杂度。第二方面, 分辨率变换模块可以对重构的 U 分量和 V 分量的分辨率进行上采样, 从而恢复出具有与原始信号分辨率相同的 U 分量和 V 分量, 第二方面的功能参见实施例 11。

[203] 针对第一方面的功能, 可以由分辨率变换模块实现, 也可以由 Y 辅助 UV 模块实现。比如说, 通过将 YUV 分量或者中间分量的分辨率降低, 可以有效减少网络复杂度, 并在网络输出位置进行分辨率的提升操作, 以恢复原始分辨率, 例如, 可以使用小波变换 (如 Haar 小波变换等), 将原始图像的分辨率减半, 这样, 网络的计算复杂度几乎可以减少四倍。当硬件对运算复杂度要求较高时, 还可以考虑连续多次使用小波变换, 使得分辨率能够进一步地降低。对于小波变换后的若干个频带, 可以全部使用也可以选取部分频带。

[204] 比如说, 参见图 7D 所示, 为后处理网络的结构示意图, 可以对 Y 初始分量进行小波变换 (图 7D 中的 DWT 变换), 得到小波变换后的多个频带, 可以将多个频带或者多个频带中的部分频带 (即 Y 子带) 输入给第一神经网络, 得到第一特征图 (Y Feature Map)。可以对 U 初始分量进行小波变换 (图 7D 中的 DWT 变换), 得到小波变换后的多个频带, 可以将多个频带或者多个频带中的部分频带 (即 U 子带) 输入给第二神经网络, 得到第二特征图 (U Feature Map)。可以对 V 初始分量进行小波变换, 得到小波变换后的多个频带, 可以将多个频带或者多个频带中的部分频带 (即 V 子带) 输入给第二神经网络, 得到第二特征图 (V Feature Map)。在得到第一特征图和 U 初始分量对应的第二特征图之后, 就可以对第一特征图和第二特征图进行特征融合, 得到 U 初始分量对应的调整后分量, 在得到第一特征图和 V 初始分量对应的第二特征图之后, 就可以对第一特征图和第二特征图进行特征融合, 得到 V 初始分量对应的调整后分量, 关于该特征融合过程, 可以参见实施例 6、实施例 7 和实施例 8。

[205] 需要注意的是, 在对第一特征图和第二特征图进行特征融合, 得到 U 初始分量对应的调整后分量时, 先采用实施例 6、实施例 7 和实施例 8, 得到融合后特征, 然后, 将融合后特征输入给神经网络 (CNN3), 得到神经网络的输出特征 (U 子带), 然后, 还可以对这个输出特征进行小波逆变换 (即小波变换的逆操作, 图 7D 中的 IDWT 变换), 得到 U 分量的调整后分量。在对第一特征图和第二特征图进行特征融合, 得到 V 初始分量对应的调整后分量时, 先采用实施例 6、实施例 7 和实施例 8, 得到融合后特征, 然后, 将融合后特征输入给神经网络 (CNN3), 得到神经网络的输出特征 (V 子带),

然后,还可以对这个输出特征进行小波逆变换(即小波变换的逆操作,图7D中的IDWT变换),得到V分量的调整后分量。

[206] 实施例13:在实施例4中,涉及YUV信号增强模块,通过YUV信号增强模块对Y分量进行信号增强,使得重构出的Y分量接近压缩前的原始信号,通过YUV信号增强模块对U分量进行信号增强,使得重构出的U分量接近压缩前的原始信号,通过YUV信号增强模块对V分量进行信号增强,使得重构出的V分量接近压缩前的原始信号。在此基础上,YUV信号增强模块可以对Y初始分量进行特征增强,得到Y分量对应的目标分量,目标分量是信号恢复后的Y分量。YUV信号增强模块可以对U分量的调整后分量进行特征增强,得到U分量对应的目标分量,目标分量是信号恢复后的U分量。YUV信号增强模块可以对V分量的调整后分量进行特征增强,得到V分量对应的目标分量,目标分量是信号恢复后的V分量。

[207] 在一种可能的实施方式中,可以通过至少一个残差块网络对Y初始分量进行特征增强,得到Y分量对应的目标分量。可以通过至少一个残差块网络对U分量的调整后分量进行特征增强,得到U分量对应的目标分量。可以通过至少一个残差块网络对V分量的调整后分量进行特征增强,得到V分量对应的目标分量。参见图7E所示,为采用残差块级联网络增强Y分量、U分量和V分量的示意图,对此残差块级联网络的结构不作限制。

[208] 在一种可能的实施方式中,可以通过U-Net网络对Y初始分量进行特征增强,得到Y分量对应的目标分量。可以通过U-Net网络对U分量的调整后分量进行特征增强,得到U分量对应的目标分量。可以通过U-Net网络对V分量的调整后分量进行特征增强,得到V分量对应的目标分量。参见图7F所示,为采用U-Net网络增强Y分量、U分量和V分量的示意图,U-Net网络包括多个下采样网络层和多个上采样网络层,对此U-Net网络的结构不作限制。

[209] 示例性的,上述各实施例可以单独实现,也可以组合实现,比如说,实施例1-实施例13中的每个实施例,可以单独实现,实施例1-实施例13中的至少两个实施例,可以组合实现。

[210] 示例性的,上述各实施例中,编码端的内容也可以应用到解码端,即解码端可以采用相同方式处理,解码端的内容也可以应用到编码端,即编码端可以采用相同方式处理。

[211] 基于与上述方法同样的申请构思,本公开实施例中还提出一种解码装置,所述解码装置应用于解码端,所述解码装置可以包括:存储器,其经配置以存储视频数据;解码器,其经配置以实现上述实施例1-实施例13中的解码方法,即解码端的处理流程。

[212] 比如说,在一种可能的实施方式中,解码器,其经配置以实现:

[213] 对当前图像块对应的码流进行解码得到重建图像块,所述重建图像块包括第一初始分量和第二初始分量,所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率;

[214] 基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量;

[215] 对所述调整后分量进行特征增强,得到所述第二初始分量对应的恢复后的目标分量。

[216] 示例性的,若所述重建图像块为YUV格式的重建图像块,则所述第一初始分量为亮度分量,所述第二初始分量为色度U分量和/或色度V分量;或,若所述重建图像

块为 RGB 格式的重建图像块, 则所述第一初始分量为 G 分量, 所述第二初始分量为 R 分量和/或 B 分量。

[217] 示例性的, 解码器, 其经配置还实现: 获取所述第一初始分量对应的第一图像特征, 所述第一图像特征包括未经过神经网络的图像特征和/或经过神经网络的图像特征; 获取所述第二初始分量对应的第二图像特征, 所述第二图像特征包括未经过神经网络的图像特征和/或经过神经网络的图像特征; 基于所述第一图像特征和所述第二图像特征生成所述调整后分量。

[218] 示例性的, 解码器, 其经配置还实现: 若所述第一图像特征包括经过神经网络的第一特征图, 所述第二图像特征包括经过神经网络的第二特征图, 在将所述第一初始分量输入给第一神经网络, 得到所述第一特征图; 将所述第二初始分量输入给第二神经网络, 得到所述第二特征图; 对所述第一特征图和所述第二特征图进行相加操作, 得到所述调整后分量; 或对所述第一特征图和所述第二特征图进行拼叠操作, 得到所述调整后分量。

[219] 示例性的, 解码器, 其经配置还实现: 若所述第一图像特征包括经过神经网络的权重系数图, 所述第二图像特征包括经过神经网络的第二特征图, 将所述第一初始分量输入给第一神经网络, 得到所述第一初始分量对应的第一特征图, 并对所述第一特征图进行引导滤波, 得到所述权重系数图; 将所述第二初始分量输入给第二神经网络, 得到所述第二特征图; 基于所述权重系数图和所述第二特征图生成所述调整后分量。

[220] 示例性的, 解码器, 其经配置还实现: 对所述第一特征图进行卷积操作, 得到卷积后特征图; 对所述卷积后特征图进行权重映射, 得到所述权重系数图。

[221] 示例性的, 解码器, 其经配置还实现: 对所述卷积后特征图进行池化操作; 对池化操作后特征图进行全连接操作和 ReLU 激活操作; 对 ReLU 激活操作后特征图进行全连接操作和 Sigmoid 激活操作; 基于所述卷积后特征图和 Sigmoid 激活操作后特征图生成所述权重系数图。

[222] 示例性的, 解码器, 其经配置还实现: 对所述卷积后特征图进行卷积操作以及 Sigmoid 激活操作, 得到所述权重系数图。

[223] 示例性的, 解码器, 其经配置还实现: 对所述权重系数图和所述第二特征图进行相乘操作, 得到相乘后特征图; 对所述第一特征图进行卷积操作, 得到卷积后特征图; 对所述相乘后特征图和所述卷积后特征图进行相加操作, 得到相加后特征图; 对所述相加后特征图和所述卷积后特征图进行拼叠操作, 得到所述调整后分量。

[224] 示例性的, 解码器, 其经配置还实现: 若所述第一图像特征包括经过神经网络的 K 个第一特征图, 所述第二图像特征包括经过神经网络的 K+1 个第二特征图, 针对首个第一特征图和首个第二特征图, 将第一初始分量输入给神经网络得到首个第一特征图, 将第二初始分量输入给神经网络得到首个第二特征图; 针对第 i 个第一特征图和第 i 个第二特征图, i 的取值范围是 2-K, K 为大于 1 的正整数, 将第 i-1 个第一特征图输入给神经网络得到第 i 个第一特征图; 对第 i-1 个第一特征图和第 i-1 个第二特征图进行特征融合得到融合后特征, 并将所述融合后特征输入给神经网络得到第 i 个第二特征图; 在得到最后一个第二特征图后, 基于最后一个第二特征图生成所述调整后分量。

[225] 示例性的, 解码器, 其经配置还实现: 从所述第一初始分量中提取 M 个维度的图像特征, M 为正整数; 对所述 M 个维度的图像特征进行拼叠, 得到拼叠后的多维度特征; 将所述多维度特征输入给第一神经网络, 得到所述第一特征图。

[226] 示例性的, 解码器, 其经配置还实现: 对所述第一初始分量进行小波变换, 得

到小波变换后的多个频带；将所述多个频带或者所述多个频带中的部分频带输入给第一神经网络，得到所述第一特征图；对所述第二初始分量进行小波变换，得到小波变换后的多个频带；将所述多个频带或者所述多个频带中的部分频带输入给第二神经网络，得到所述第二特征图。

[227] 示例性的，解码器，其经配置还实现：对所述第一初始分量进行预处理，得到预处理后的第一初始分量；其中，所述预处理后的第一初始分量用于输入给所述第一神经网络得到所述第一特征图；解码器，其经配置还实现：对所述第一初始分量进行边缘增强，得到边缘增强后的图像特征；对所述边缘增强后的图像特征进行多尺度的特征提取，得到多尺度特征；基于所述多尺度特征确定所述预处理后的第一初始分量。

[228] 示例性的，解码器，其经配置还实现：对所述边缘增强后的图像特征进行卷积操作，得到卷积后特征；对所述卷积后特征进行下采样操作，得到下采样后特征；对所述下采样后特征进行通道变换，得到通道变换后特征；对所述通道变换后特征进行上采样操作，得到上采样后特征；基于所述上采样后特征和通道变换后特征生成所述多尺度特征。

[229] 示例性的，解码器，其经配置还实现：在基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量之前，对所述第二初始分量进行上采样，得到上采样后的第二初始分量；所述上采样后的第二初始分量的分辨率等于所述第一初始分量的分辨率。

[230] 示例性的，解码器，其经配置还实现：在对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量之前，对所述调整后分量进行上采样，得到上采样后的调整后分量；其中，上采样后的调整后分量的分辨率等于所述第一初始分量的分辨率。

[231] 示例性的，解码器，其经配置还实现：在对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量之后，对所述目标分量进行上采样，得到上采样后的目标分量；其中，上采样后的目标分量的分辨率等于所述第一初始分量的分辨率。

[232] 示例性的，解码器，其经配置还实现：通过至少一个残差块网络对所述调整后分量进行特征增强，得到所述第二初始分量对应的目标分量；或者，通过 U-Net 网络对所述调整后分量进行特征增强，得到所述第二初始分量对应的目标分量。

[233] 基于与上述方法同样的申请构思，本公开实施例提供的解码端设备（也可以称为视频解码器），从硬件层面而言，其硬件架构示意图具体可以参见图 8 所示。包括：处理器 811 和机器可读存储介质 812，机器可读存储介质 812 存储有能够被处理器 811 执行的机器可执行指令；处理器 811 用于执行机器可执行指令，以实现本公开上述实施例 1-12 的解码方法。

[234] 比如说，在一种可能的实施方式中，处理器 811 执行机器可执行指令时用于实现：

[235] 对当前图像块对应的码流进行解码得到重建图像块，所述重建图像块包括第一初始分量和第二初始分量，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率；

[236] 基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量；

[237] 对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标

分量。

[238] 基于与上述方法同样的申请构思，本公开实施例提供一种电子设备。包括：处理器和机器可读存储介质，机器可读存储介质存储有能够被处理器执行的机器可执行指令；处理器用于执行机器可执行指令，以实现本公开上述实施例 1-12 的解码方法。

[239] 基于与上述方法同样的申请构思，本公开实施例还提供一种机器可读存储介质，所述机器可读存储介质上存储有若干计算机指令，所述计算机指令被处理器执行时，能够实现本公开上述示例公开的方法，如上述各实施例中的解码方法。

[240] 基于与上述方法同样的申请构思，本公开实施例还提供一种计算机应用程序，所述计算机应用程序令被处理器执行时，能够实现本公开上述示例公开的解码方法。

[241] 基于与上述方法同样的申请构思，本公开实施例中还提出一种解码装置，所述解码装置可以应用于解码端（也可以称为视频解码器），所述解码装置可以包括：

[242] 解码模块，用于对当前图像块对应的码流进行解码得到重建图像块，所述重建图像块包括第一初始分量和第二初始分量，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率；确定模块，用于基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量；处理模块，用于对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量。

[243] 示例性的，若所述重建图像块为 YUV 格式的重建图像块，则所述第一初始分量为亮度分量，所述第二初始分量为色度 U 分量和/或色度 V 分量；或，若所述重建图像块为 RGB 格式的重建图像块，则所述第一初始分量为 G 分量，所述第二初始分量为 R 分量和/或 B 分量。

[244] 示例性的，所述确定模块基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量时具体用于：获取所述第一初始分量对应的第一图像特征，所述第一图像特征包括未经过神经网络的图像特征和/或经过神经网络的图像特征；获取所述第二初始分量对应的第二图像特征，所述第二图像特征包括未经过神经网络的图像特征和/或经过神经网络的图像特征；基于所述第一图像特征和所述第二图像特征生成所述调整后分量。

[245] 示例性的，若所述第一图像特征包括未经过神经网络的图像特征，所述第一图像特征包括以下至少一种：纹理特征、主观特征、频域特征、或直方图特征；若所述第二图像特征包括未经过神经网络的图像特征，所述第二图像特征包括以下至少一种：纹理特征、主观特征、频域特征、或直方图特征。

[246] 示例性的，若所述第一图像特征包括经过神经网络的第一特征图，所述第二图像特征包括经过神经网络的第二特征图，所述确定模块基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量时具体用于：将所述第一初始分量输入给第一神经网络，得到所述第一特征图；将所述第二初始分量输入给第二神经网络，得到所述第二特征图；对所述第一特征图和所述第二特征图进行相加操作，得到所述调整后分量；或对所述第一特征图和所述第二特征图进行拼叠操作，得到所述调整后分量。

[247] 示例性的，若所述第一图像特征包括经过神经网络的权重系数图，所述第二图像特征包括经过神经网络的第二特征图，所述确定模块基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量时具体用于：将所述第一初始分量输入给第一神经网络，得到所述第一初始分量对应的第一特征图，并对所述第一特征图进行引导滤波，得到所述权重系数图；将所述第二初始分量输入给第二神经网络，得到所述第二特征图；基于所述权重系数图和所述第二特征图生成所述调整后分量。

[248] 示例性的,所述确定模块对所述第一特征图进行引导滤波,得到所述权重系数图时具体用于:对所述第一特征图进行卷积操作,得到卷积后特征图;对所述卷积后特征图进行权重映射,得到所述权重系数图。

[249] 示例性的,所述确定模块对所述卷积后特征图进行权重映射,得到所述权重系数图时具体用于:对所述卷积后特征图进行池化操作;对池化操作后特征图进行全连接操作和修正线性单元 ReLU 激活操作;对 ReLU 激活操作后特征图进行全连接操作和 S 形曲线 Sigmoid 激活操作;基于所述卷积后特征图和 Sigmoid 激活操作后特征图生成所述权重系数图。

[250] 示例性的,所述确定模块对所述卷积后特征图进行权重映射,得到所述权重系数图时具体用于:对所述卷积后特征图进行卷积操作以及 Sigmoid 激活操作,得到所述权重系数图。

[251] 示例性的,所述确定模块基于所述权重系数图和所述第二特征图生成所述调整后分量时具体用于:对所述权重系数图和所述第二特征图进行相乘操作,得到相乘后特征图;对所述第一特征图进行卷积操作,得到卷积后特征图;对所述相乘后特征图和所述卷积后特征图进行相加操作,得到相加后特征图;对所述相加后特征图和所述卷积后特征图进行拼叠操作,得到所述调整后分量。

[252] 示例性的,若所述第一图像特征包括经过神经网络的 K 个第一特征图,所述第二图像特征包括经过神经网络的 $K+1$ 个第二特征图,所述确定模块基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量时具体用于:针对首个第一特征图和首个第二特征图,将第一初始分量输入给神经网络得到首个第一特征图,将第二初始分量输入给神经网络得到首个第二特征图;针对第 i 个第一特征图和第 i 个第二特征图, i 的取值范围是 2 到 K , K 为大于 1 的正整数,将第 $i-1$ 个第一特征图输入给神经网络得到第 i 个第一特征图;对第 $i-1$ 个第一特征图和第 $i-1$ 个第二特征图进行特征融合得到融合后特征,并将所述融合后特征输入给神经网络得到第 i 个第二特征图;在得到最后一个第二特征图后,基于最后一个第二特征图生成所述调整后分量。

[253] 示例性的,所述确定模块对第一特征图和第二特征图进行特征融合得到融合后特征时具体用于:对第一特征图和第二特征图进行相加操作,得到所述融合后特征;或,对第一特征图和第二特征图进行拼叠操作,得到融合后特征;或,对第一特征图进行引导滤波,得到所述第一特征图对应的权重系数图,基于所述权重系数图和第二特征图生成所述融合后特征。

[254] 示例性的,所述确定模块将所述第一初始分量输入给第一神经网络,得到所述第一特征图时具体用于:从所述第一初始分量中提取 M 个维度的图像特征, M 为正整数;对所述 M 个维度的图像特征进行拼叠,得到拼叠后的多维度特征;将所述多维度特征输入给第一神经网络,得到所述第一特征图。

[255] 示例性的,所述 M 个维度的图像特征包括以下至少一种:采用一个卷积核对所述第一初始分量进行卷积后的图像特征;采用两个卷积核对所述第一初始分量进行卷积级联后的图像特征;采用索贝尔 (sobel) 算子对所述第一初始分量进行处理后的一阶空域特征;采用拉普拉斯 (Laplacian) 算子对所述第一初始分量进行处理后的二阶空域特征;或对所述第一初始分量进行傅里叶变换后的频域特征。

[256] 示例性的,所述确定模块将所述第一初始分量输入给第一神经网络,得到所述第一特征图时具体用于:对所述第一初始分量进行小波变换,得到小波变换后的多个频带;将所述多个频带或者所述多个频带中的部分频带输入给第一神经网络,得到所述第一特征图;所述确定模块将所述第二初始分量输入给第二神经网络,得到所述第二特征

图时具体用于：对所述第二初始分量进行小波变换，得到小波变换后的多个频带；将所述多个频带或者所述多个频带中的部分频带输入给第二神经网络，得到所述第二特征图。

[257] 示例性的，所述确定模块将所述第一初始分量输入给第一神经网络，得到所述第一特征图之前还用于：对所述第一初始分量进行预处理，得到预处理后的第一初始分量；其中，所述预处理后的第一初始分量用于输入给所述第一神经网络得到所述第一特征图。所述确定模块对所述第一初始分量进行预处理，得到预处理后的第一初始分量时具体用于：对所述第一初始分量进行边缘增强，得到边缘增强后的图像特征；对所述边缘增强后的图像特征进行多尺度的特征提取，得到多尺度特征；基于所述多尺度特征确定所述预处理后的第一初始分量。

[258] 示例性的，所述确定模块对所述边缘增强后的图像特征进行多尺度的特征提取，得到多尺度特征时具体用于：对所述边缘增强后的图像特征进行卷积操作，得到卷积后特征；对所述卷积后特征进行下采样操作，得到下采样后特征；对所述下采样后特征进行通道变换，得到通道变换后特征；对所述通道变换后特征进行上采样操作，得到上采样后特征；基于所述上采样后特征和通道变换后特征生成所述多尺度特征。

[259] 示例性的，所述处理模块在基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量之前还用于，对所述第二初始分量进行上采样，得到上采样后的第二初始分量；其中，所述上采样后的第二初始分量的分辨率等于所述第一初始分量的分辨率。

[260] 示例性的，所述处理模块在对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量之前，还用于对所述调整后分量进行上采样，得到上采样后的调整后分量；其中，上采样后的调整后分量的分辨率等于所述第一初始分量的分辨率。

[261] 示例性的，所述处理模块对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量之后，还用于对所述目标分量进行上采样，得到上采样后的目标分量；其中，上采样后的目标分量的分辨率等于所述第一初始分量的分辨率。

[262] 示例性的，所述处理模块对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量时具体用于：通过至少一个残差块网络对所述调整后分量进行特征增强，得到所述目标分量；或者，通过 U-Net 网络对所述调整后分量进行特征增强，得到所述目标分量。

[263] 本领域内的技术人员应明白，本公开实施例可提供为方法、系统、或计算机程序产品。本公开可采用完全硬件实施例、完全软件实施例、或结合软件和硬件方面的实施例的形式。本公开实施例可采用在一个或多个其中包含有计算机可用程序代码的计算机可用存储介质（包括但不限于磁盘存储器、CD-ROM、光学存储器等）上实施的计算机程序产品的形式。以上所述仅为本公开的实施例而已，并不用于限制本公开。

[264] 对于本领域技术人员来说，本公开可以有各种更改和变化。凡在本公开的精神和原理之内所作的任何修改、等同替换、改进等，均应包含在本公开的权利要求范围之内。

权利要求书

1、一种解码方法，其特征在于，所述方法包括：

对当前图像块对应的码流进行解码得到重建图像块，所述重建图像块包括第一初始分量和第二初始分量，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率；

基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量；

对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量。

2、根据权利要求1所述的方法，其特征在于，所述重建图像块为 YUV 格式的重建图像块，所述第一初始分量为亮度分量，所述第二初始分量为色度 U 分量和色度 V 分量。

3、根据权利要求1所述的方法，其特征在于，所述基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量，包括：

获取所述第一初始分量对应的第一图像特征，所述第一图像特征包括未经过神经网络的图像特征；

获取所述第二初始分量对应的第二图像特征，所述第二图像特征包括未经过神经网络的图像特征；

基于所述第一图像特征和所述第二图像特征生成所述调整后分量。

4、根据权利要求3所述的方法，其特征在于，所述第一图像特征包括 Haar 小波频域特征；所述第二图像特征包括 Haar 小波频域特征。

5、根据权利要求1或3所述的方法，其特征在于，所述基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量，包括：

对所述第一初始分量进行至少一次 Haar 小波变换，得到变换后的多个频带作为第一特征图；

对所述第二初始分量进行至少一次 Haar 小波变换，得到变换后的多个频带作为第二特征图；

对所述第一特征图和所述第二特征图进行拼叠操作，得到所述调整后分量。

6、根据权利要求5所述的方法，其特征在于，所述对所述第一特征图和所述第二特征图进行拼叠操作，包括：

沿通道维度对所述第一特征图和所述第二特征图进行拼叠操作。

7、根据权利要求5所述的方法，其特征在于，

所述对所述第一初始分量进行至少一次 Haar 小波变换，得到变换后的多个频带，包括：

对所述第一初始分量进行两次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带；

所述对所述第二初始分量进行至少一次 Haar 小波变换，得到变换后的多个频带，包括：

对所述第二初始分量进行两次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带。

8、根据权利要求5所述的方法，其特征在于，

所述对所述第一初始分量进行多次 Haar 小波变换，得到变换后的多个频带，包括：

对所述第一初始分量进行两次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带；

所述对所述第二初始分量进行多次 Haar 小波变换，得变换后的多个频带，包括：

对所述第二初始分量进行两次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带。

9、根据权利要求 7 或 8 所述的方法，其特征在于，

所述对所述第一初始分量进行两次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带，包括：

对所述第一初始分量进行第一次 Haar 小波变换，得到第一次 Haar 小波变换后的多个频带；

对所述第一次 Haar 小波变换后的多个频带进行第二次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带；

所述对所述第二初始分量进行两次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带，包括：

对所述第二初始分量进行第一次 Haar 小波变换，得到第一次 Haar 小波变换后的多个频带；

对所述第一次 Haar 小波变换后的多个频带进行第二次 Haar 小波变换，得到所述两次 Haar 小波变换后的多个频带。

10、根据权利要求 1-9 任一项所述的方法，其特征在于，所述对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量，包括：

通过多个残差块网络对所述调整后分量进行特征增强，得到所述目标分量。

11、一种编码方法，其特征在于，所述方法包括：

对当前图像块的第一初始分量和第二初始分量进行编码，得到所述当前图像块对应的码流，其中，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率。

12、根据权利要求 11 所述的方法，其特征在于，所述当前图像块为 YUV 格式，所述第一初始分量为亮度分量，所述第二初始分量为色度 U 分量和色度 V 分量。

13、一种解码装置，其特征在于，所述装置包括：

解码模块，用于对当前图像块对应的码流进行解码得到重建图像块，所述重建图像块包括第一初始分量和第二初始分量，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率；

确定模块，用于基于所述第一初始分量和所述第二初始分量生成所述第二初始分量对应的调整后分量；

处理模块，用于对所述调整后分量进行特征增强，得到所述第二初始分量对应的恢复后的目标分量。

14、一种编码装置，其特征在于，所述装置包括：

编码模块，用于对当前图像块的第一初始分量和第二初始分量进行编码，得到所述当前图像块对应的码流，其中，所述第一初始分量的分辨率大于或者等于所述第二初始分量的分辨率。

15、一种解码端设备，其特征在于，包括：处理器和机器可读存储介质，所述机器可读存储介质存储有能够被所述处理器执行的机器可执行指令；

所述处理器用于执行机器可执行指令，以实现权利要求 1-10 任一项所述的方法。

16、一种编码端设备，其特征在于，包括：处理器和机器可读存储介质，所述机器可读存储介质存储有能够被所述处理器执行的机器可执行指令；

所述处理器用于执行机器可执行指令，以实现权利要求 11-12 任一项所述的方法。

17、一种机器可读存储介质，其特征在于，所述机器可读存储介质上存储有若干计算机指令，所述计算机指令被处理器执行时，实现如权利要求 1-10 任一项所述的解码方法，或实现如权利要求 11-12 任一项所述的编码方法。

18、一种计算机程序产品，包括计算机程序，其特征在于，所述计算机程序被处理器执行时实现如权利要求 1-10 中任一项所述的解码方法，或，实现如权利要求 11-12 中任一项所述的编码方法。