

文章编号: 2095-2163(2020)03-0386-06

中图分类号: TP391.41

文献标志码: A

# 基于神经网络的 HEVC 帧间预测

王洋, 高文

(哈尔滨工业大学 计算机科学与技术学院, 哈尔滨 150001)

**摘要:** 高效视频编码标准 HEVC 是最新的数字视频编码标准, 其中, 帧间预测在去除时域相关性方面扮演重要角色。在传统的帧间预测方法中, 因为仅仅利用了时域信息, 所以帧间预测的准确性是有限的。在本文中, 提出了利用时域-空域信息的基于神经网络的 HEVC 帧间预测算法。具体来讲, 在本文提出的算法中, 首先设计了一个包含全连接网络 (fully connected network, FCN) 和卷积神经网络 (convolutional neural network, CNN) 的神经网络结构。其次, 时域相邻像素和空域相邻像素输入到 FCN 网络, FCN 网络输出的结果和当前预测块输入到 CNN 网络中, CNN 网络生成最终的当前块的更准确的预测块。实验结果表明, 与 HEVC 参考软件 HM 16.9 在通用测试条件 Low Delay P (LDP) 下编码, 本文提出的算法能够带来平均 1.7% (高达 8.6%) 的 BD-rate 节省。

**关键词:** HEVC; 帧间预测; 神经网络; 卷积神经网络; 全连接网络

## Neural network based inter prediction for HEVC

WANG Yang, GAO Wen

(School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001, China)

**[Abstract]** HEVC is the latest video coding standard, in which inter prediction plays an important role to reduce the temporal redundancy. The accuracy of inter prediction is limited since only temporal information is used in conventional algorithms. This paper proposes a neural network based inter prediction algorithm for HEVC by using the spatial-temporal information. In the proposed algorithm, first a neural network architecture is designed consisting of a fully connected network (FCN) and a convolutional neural network (CNN). Then the spatial neighboring pixels and the temporal neighboring pixels are inputted into FCN. The output of FCN and the prediction of current block are inputted into CNN, which will generate the more accurate prediction of current block. Experimental results demonstrate that the proposed method can achieve average 1.7% (up to 8.6%) BD-rate reduction in low delay P test condition compared to HM 16.9.

**[Key words]** HEVC; inter prediction; neural network; CNN; FCN

## 0 引言

随着通信技术、互联网技术的发展和移动终端、智能设备的普及, 作为信息载体的视频在人们生活的方方面面都扮演着不可或缺的角色。数字广播电视、互联网视频、视频会议、远程医疗、远程教育等传统多媒体应用一直影响和改变着人们的工作学习和生活娱乐的方式。视频数据呈爆炸式增长, 给数据存储和网络传输带来巨大挑战, 如何稳定高效地存储和传输海量的视频数据成为目前亟待解决的问题。为了高效地压缩高清和超高清数字视频, 国际标准组织制定了相应的数字视频编码标准。国际的视频编码联合协作组 JCTVC 制定的高效视频编码标准 HEVC 于 2013 年 1 月正式发布, 相比于上一代数字视频编码标准 H.264/AVC, 在获得相同主观质量的条件下, HEVC 能够节省大约 50% 的码率, 极大

地提高了视频编码的压缩性能。HEVC 中的帧间预测方法中, 能够很好的处理视频中的平移运动。然而, 自然视频中的运动类型种类多样、复杂性高, 简单的平移运动并不能涵盖所有的情况。自然视频中会包含许多复杂的运动, 如非线性的亮度变化、缩放和模糊等。

## 1 提出的基于神经网络的 HEVC 帧间预测算法

在本节中, 将详述本次研究所提出的基于神经网络的 HEVC 帧间预测算法。首先, 简要讨论了 HEVC 的帧间预测和本文所用的基础网络 VRCNN; 其次, 介绍提出的算法的网络结构; 再次, 给出了本文设计的网络的训练策略; 最后, 将本文提出的算法集成到 HEVC 以提高其压缩性能。

### 1.1 HEVC 帧间预测及 VRCNN

帧间预测在 HEVC 中发挥着重要作用, 可以通

**基金项目:** 国家 973 项目 (2015CB351804)。

**作者简介:** 王洋 (1990-), 男, 博士研究生, 主要研究方向: 视频编码、深度学习、计算机视觉; 高文 (1963-), 男, 博士, 教授, 博士生导师, 主要研究方向: 人工智能、计算机视觉、模式识别与图像处理、多媒体数据压缩、多模式接口以及虚拟现实等。

**收稿日期:** 2019-04-06

过提高帧间预测的准确性,从而提高 HEVC 的压缩性能。编码单元(Coding Unit, CU)是 HEVC 中编码的基本单位,每个 CU 都被设定为一种预测模式:帧内预测或帧间预测。每个 CU 都包含了一个或多个预测单元(Prediction Unit, PU)。如图 1 所示,对于帧间编码的 CU,一共有 8 种 PU 划分模式。




图 1 帧间预测 CU 的 PU 划分模式

Fig. 1 PU partitioning modes for inter CU

HEVC 中使用帧间预测进行编码和解码的简化框图如图 2 所示。在编码端,帧间预测用于生成当前块的预测,或者使用常规的帧间预测模式,或者使用 Merge 模式。常规的帧间预测模式中,运动估计用来获取运动矢量(motion vector, MV),这个 MV 在运动补偿中用来生成最终的预测值。之后,变换、量化、熵编码用来生成最终的码流。在解码端,从熵解码阶段获取 MV 和残差,通过将残差与预测值相加获取重构视频。

本文的网络结构中利用了文献[1]提出的 VRCNN 网络, VRCNN 用来去除 HEVC 帧内编码产生的噪声。研究可知, VRCNN 的结构。见表 1。 VRCNN 中有 4 个全卷积层,其中第二层和第三层采用了可变滤波尺寸,不同的滤波尺寸卷积层产生的特征图聚合到一起,并输入到下一层。第一层和最后一层不使用可变的滤波尺寸。 VRCNN 采用了最近发明的残差学习技术<sup>[2]</sup>,因此网络的输出加上网络输入为最终的结果。

表 1 VRCNN 的网络参数<sup>[1]</sup>

Tab. 1 The parameters of VRCNN<sup>[1]</sup>

Layer	Layer 1	Layer 2	Layer 3	Layer 4		
Conv.module	conv1	conv2	conv3	conv4	conv5	conv6
Filter size	5×5	5×5	3×3	3×3	1×1	3×3
#filters	64	16	32	16	32	1
#parameters	1 600	25 600	18 432	6 912	1 536	432
Totalparameters	54 512					

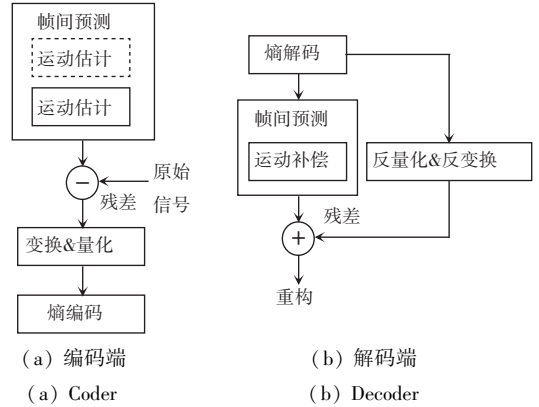


图 2 HEVC 帧间预测过程

Fig. 2 HEVC inter prediction

1.2 基于神经网络的 HEVC 帧间预测的网络结构

本文提出了基于神经网络的 HEVC 帧间预测算法 (Neural network based inter prediction for HEVC, NNIP)。 NNIP 的网络结构如图 3 所示。 NNIP 由 2 个网络组成,分别是:全连接网络 (Fully connected network, FCN) 和卷积神经网络 (Convolutional neural network, CNN)。 NNIP 的网络输入有 3 个:空域相邻像素、时域相邻像素、当前块的预测值,这里用 S、T、C 来表示这三个输入。如图 4 所示, S 和 T 作为 FCN 的输入, FCN 的输出结果与预测值 C 相加,相加后的结果输入到 CNN 网络中,网络的最终输出结果是改善后的预测值。

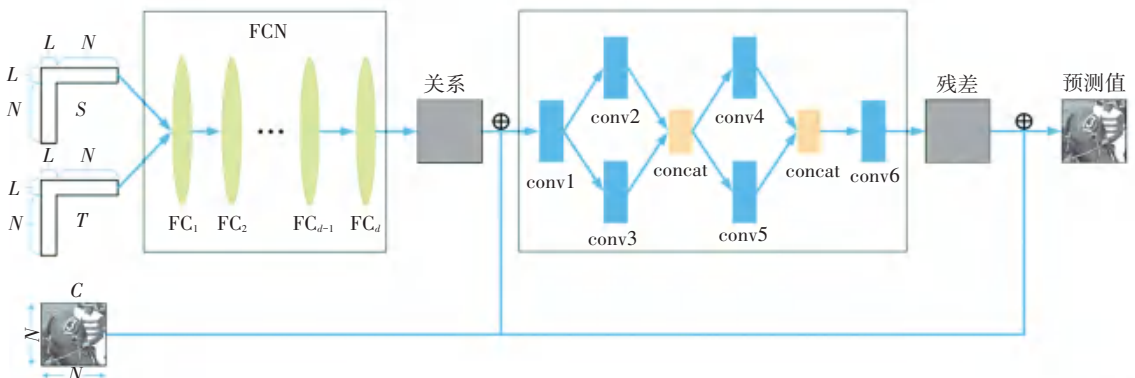


图 3 基于神经网络的 HEVC 帧间预测的网络结构

Fig. 3 The network structure of neural network based inter prediction




图4 NNIP网络的输入

Fig. 4 The input of NNIP

在FCN中,对于一个大小为 $N \times N$ 的帧间预测块,研究使用 $S$ 和 $T$ 作为输入,详见图4。 $FC_i$ 表示第 $i$ 层全连接层, $d$ 表示FCN网络的深度。用 $Y$ 表示网络的输入, $G_i(Y)$ 表示第 $i$ 层网络的输出,FCN最终的输出用 $G(Y) = G_d(Y)$ 表示,各层网络输出则可以用如下公式进行表示:

$$\begin{aligned} G_1(Y) &= f(W_{1,F} \cdot Y + B_{1,F}), \quad i = 1, \\ G_i(Y) &= f(W_{i,F} \cdot G_{i-1}(Y) + B_{i,F}), \quad 1 < i \leq d. \end{aligned} \quad (1)$$

其中, $W_{i,F}$ 和 $B_{i,F}$ 表示FCN中第 $i$ 层的权重参数和偏置参数;“ $\cdot$ ”表示内积操作; $f(\cdot)$ 表示非线性映射函数,本文中使用的parameter rectified linear unit (PReLU)<sup>[3]</sup>作为非线性映射函数。

对于FCN中的第一层( $i = 1$ ), $G_1(Y)$ 的维度是 $4NL + 2L^2$ 。对于FCN的隐含层( $1 < i < d$ ), $G_i(Y)$ 的维度是 $K$ ,这一层是第 $i - 1$ 层的输出。对于FCN中的最后一层( $i = d$ ), $G_d(Y)$ 的维度是 $N^2$ ,最后一层需要改造成FCN的输出,和大小为 $N \times N$ 块的尺寸一致。

如上文所述,FCN网络的输出结果和当前块的预测值 $C$ 相加,并将这个相加的结果作为CNN网络的输入,参见图4。在本文中,VRCNN作为本文CNN的一个样例网络,VRCNN中每一层的网络配置详见表1。类似于FCN,CNN网络可以用如下公式进行表示:

$$\begin{aligned} F_1(Y) &= g(W_{1,C} * Y + B_{1,C}), \quad i = 1, \\ F_i(Y) &= g(W_{i,C} * F_{i-1}(Y) + B_{i,C}), \quad 1 < i < d', \end{aligned} \quad (2)$$

其中, $W_{i,C}$ 和 $B_{i,C}$ 表示CNN网络中第 $i$ 个卷积层的权重参数和偏置参数;“ $*$ ”表示卷积操作; $g(\cdot)$ 表示非线性激活函数; $d'$ 表示CNN的网络深度,在VRCNN中为4。

VRCNN采用了最近发明的残差学习技术<sup>[2]</sup>,因此网络的输出加上网络输入即为最终的结果。如此一来,其数学公式就可以表示为:

$$F(Y) = W_{4,C} * F_3(Y) + B_{4,C} + Y, \quad (3)$$

其中, $W_{4,C}$ 和 $B_{4,C}$ 表示VRCNN最后一个卷积层

的权重参数和偏置参数, $F_3(Y)$ 表示第三个卷积层的输出结果。类似地,残差学习技术也可以引入本文提出的网络中用来加速训练过程。然而,和VRCNN不同的是,最终的输出结果是CNN的输出结果和当前块预测值 $C$ 的加和,可以用如下公式来表示:

$$F(Y) = W_{4,C} * F_3(Y) + B_{4,C} + C. \quad (4)$$

CNN网络中的每一层的参数和VRCNN的参数一样。本文在卷积过程中将使用0填充保证输入块和输出块的尺寸一致。因此,整个网络的输出结果是一个尺寸为 $N \times N$ 的块,为当前预测块提升后的结果。

### 1.3 网络训练策略

在这里,将探讨本文提出的NNIP网络的训练策略。主要集中在训练数据的生成和超参数的设置上。用 $(x_i, y_i)$ 表示每个训练样本,其中 $x_i$ 表示网络的输入,由 $S, T, C$ 组成, $y_i$ 表示当前预测块 $C$ 的标签,是当前块的原始信号。研究使用HM 16.9在LDP配置的HEVC通测条件<sup>[4]</sup>下编码3个HEVC视频序列(BasketballDrive、BQMall、BlowingBubbles)。这3个序列的所有帧都使用不同的量化参数(quantization parameters, QP)编码。而后从编码后的码流中提取 $x_i$ ,从视频序列的原始信号中提取 $y_i$ 。

学习从网络输入到当前块提升的预测块的全部映射 $F$ 需要估计网络的参数。具体来讲,给定 $n$ 个训练样本,其中第 $i$ 个样例由输入 $x_i$ 和原始信号 $y_i$ 组成,研究使用均方误差标准(mean squared error, MSE)来最小化如下损失函数,此时将用到如下数学公式:

$$L(\Theta) = \frac{1}{n} \sum_{i=1}^n \| F(x_i | \Theta) - y_i \|^2. \quad (5)$$

其中, $\Theta = \{W_{j,F}, B_{j,F}, W_{k,C}, B_{k,C}\}, 1 \leq j \leq d, 1 \leq k \leq d', n$ 是训练样本的总数。

本文中,研究在NVIDIA GeForce GTX 1080的GPU上使用Caffe<sup>[5]</sup>深度学习框架来训练提出的NNIP的网络。使用基于一阶梯度的Adam<sup>[6]</sup>优化策略来最小化损失函数,实验中采用基于批量学习的方法,其中批量大小设置为64。Adam优化中的momentum设置为0.9, momentum2设置为0.99。FCN网络的深度 $d$ 设置为4,FCN中隐含层的维度 $K$ 设置为2倍的网络输入。基本的学习率设置为从0.1到0.0001的指数下降,每40个epochs改变一次,这样训练过程一共需要160个epochs完成。研究中按照如上的学习率设置训练QP=37的网络,其他QP的模型(QP=22,27,32)通过使用QP=37

网络模型的调优方式来得到, 这时候, 基本的学习率设置为 0.001。此外, 对于不同的 CU 大小(8×8、16×16、32×32、64×64), 还将训练不同的网络模型, 因此对于不同的 CU 大小和不同的 QP, 研究提出的 NNIP 网络一共有 16 个模型。

### 1.4 集成到 HEVC

研究中, 通过将提出的 NNIP 集成到 HEVC 中来提升 HEVC 的压缩性能, 从而验证 NNIP 的有效性。NNIP 用来提升帧间预测的准确性, 其在 HEVC 编解码器中的位置处于传统的帧间预测方法之后。NNIP 集成到 HEVC 中简化的框图如图 5 所示。




图 5 NNIP 集成到 HEVC 中的简化框图

Fig. 5 The simplified diagram of NNIP integrated in HEVC

由图 5(a)可知, 在 HEVC 编码的过程中, NNIP 用在帧间预测之后。研究发现, 与相邻像素、时域相邻像素和当前块的预测值输入到 NNIP 网络, NNIP 网络的输出是提升后的当前块的预测值。由图 5(b)可知, 在 HEVC 的解码过程中, NNIP 也是应用在帧间预测后用来生成当前块更加准确的预测块。

本文提出的 NNIP 算法能够提高 HEVC 帧间预测的准确性。首先, 空域相邻像素和是与相邻像素通过 FCN 学习得到相互之间的相关性; 其次, 这个结果和当前块的预测值相加, 相加的结果用 CNN 进一步提升性能。在本文中, 只有 HEVC 的亮度分量用 NNIP 来提升性能, NNIP 算法仅应用在常规帧间预测、Merge 模式和 Skip 模式的  $2N \times 2N$  的 PU 划分的 CU 上。考虑到一些简单的纹理使用传统的帧间预测方法能够很好地获取当前块的预测值, 因此对于使用一个 CU 级别的标志位来表示这个 CU 是否使用 NNIP 方法, 是否使用 NNIP 方法通过率失真优化(rate distortion optimization, RDO)来决定。

## 2 实验结果及分析

在本节中, 研究进行了大量的实验来验证提出的基于神经网络的 HEVC 帧间预测算法的有效性。对此可做研究分述如下。

### 2.1 实验配置

本文提出的 NNIP 算法集成到 HEVC 的参考软件 HM 16.9 中, 实验中遵循 HEVC 的通用测试条

件<sup>[4]</sup>配置编解码器, 使用 LDP 配置来验证 NNIP 在 HEVC 上的性能。一共 18 个 8 位深的视频测试序列用来验证结果, 编码其中的前 64 帧, 用到的测试序列为: Class A (2 560×1 080, 4 K×2 K)、Class B (1 920×1 080, 1 080P)、Class C (832×480, WVGA)、Class D (416×240, QVGA)、Class E (1 280×720, 720P)。实验中使用的 QP 为 22、27、32、37。使用的机器的配置是主频为 3.4 GHz 的 Intel i7-6700QP 处理器和 64 GB 的内存, 操作系统为 Microsoft Windows Server 2012 R2。HM 16.9 和提出的 NNIP 算法都使用 Microsoft Visual Studio 2013 编译, 当把 NNIP 集成到 HEVC 时, NNIP 网络的前馈操作使用 GPU 版本的 Caffe 来实现。

### 2.2 NNIP 的压缩性能

使用双三次插值的 Bjontegaard 失真率 (BD-rate)<sup>[15]</sup>来评估 NNIP 的压缩性能。对于 BD-rate, 负数表示相同质量下比特率节省, 正数表示相同质量下比特率增加。和 HM 16.9 相比, NNIP 的压缩性能见表 2。由表 2 可知, 本文提出的算法在亮度分量上, 能够获得平均 1.7% (最大达 8.6%) 的性能提升, 验证了本文算法的有效性。

表 2 与 HM 16.9 对比 NNIP 算法亮度分量的 BD-rate

Tab. 2 The BD-rate of NNIP for luma component compared with HM 16.9

类别	分辨率	序列	Y / %
Class A	2 560×1 600	Traffic	-1.5
		PeopleOnstreet	-0.6
Class B	1 920×1 080	Kimono	-1.9
		ParkScene	-0.3
		Cactus	-2.3
		BasketballDrive*	-3.8
Class C	832×480	BQTerrace	-8.6
		BasketballDrill	-1.3
		BQMall*	-2.2
Class D	416×240	PartyScene	-0.7
		RaceHorses	-0.6
		BasketballPass	-0.9
		BQSquare	-1.3
		BlowingBubbles*	-0.7
Class E	1 280×720	RaceHorses	-0.6
		FourPeople	-1.5
		Johny	-2.0
		KristenAndSara	-2.1
Average			-1.7

由表2可知,对于所有的测试序列,本文提出的NNIP算法都能够带来性能的提升。但是,对于不同的测试序列,压缩性能的提升变化比较明显,表明提出的NNIP的算法受视频序列内容的影响比较大。本文提出的NNIP算法对于运动剧烈或者纹理丰富的视频序列能够带来比较好的压缩性能,如BasketballDrive、BQTerrace、BQMall。此外,对于会议视频,如Class E, NNIP的压缩性能也是十分可观的。尽管研究中使用了3个HEVC的视频序列来训练网络,但是这三个序列的压缩性能并没有比其它序列的性能获得显著提升。在将来的工作中,研究会扩展训练集并且去除HEVC的测试序列,用以有效验证提出的NNIP算法的有效性。

为了进一步验证提出的NNIP算法的压缩性能,研究也比较NNIP和传统帧间预测方法的主观视觉效果。如图6所示,无论对于低码率视频 $QP = 37$ 、还是高码率视频 $QP = 27$ ,本文提出的NNIP算法都能够获得更好的主观视觉效果。




图6 NNIP算法的主观视觉效果

Fig. 6 The visual results of NNIP

### 2.3 NNIP的计算复杂度

本文提出的NNIP算法的编解码的计算复杂度见表3。计算复杂度采用运行时间增加比例来衡量,其数学公式可写为如下数学形式:

$$\Delta T = \frac{T_p - T_o}{T_o} \times 100\%. \quad (6)$$

其中,  $\Delta T$  表示编码或者解码时间的增加;  $T_o$  和  $T_p$  分别表示HM 16.9的编码(解码)时间和提出的NNIP算法的编码(解码)时间;  $DT_{enc}$  和  $DT_{dec}$  分别表示表3中编码和解码的时间增加比率。

表3 NNIP的计算复杂度

Tab. 3 The computational complexity of NNIP	$DT_{enc}$	$DT_{dec}$
Class A	3 273	1 700
Class B	3 314	3 301
Class C	2 479	2 416
Class D	2 842	1 578
Class E	5 310	1 113
Average	3 444	2 022

由表3可知,使用NNIP算法时,编码时间平均增加了3 444%,解码时间平均增加了2 022%。如此高的计算复杂度主要来源于2个方面,对此则可表述如下:

(1)对于所有不同尺寸的CU的所有帧间预测模式都要进行率失真代价决策计算,会导致计算复杂度数倍地增加。

(2)相比HEVC本身算法来讲,提出的网络的前馈操作具有较高的计算复杂度。在未来的研究工作中,将会考虑开展降低算法计算复杂度方面的研究。

### 3 结束语

在本文中,设计研发了一种基于神经网络的HEVC帧间预测算法。研究中,提出了一种融合全连接网络和卷积神经网络的神经网络结构,其中空域相邻像素、时域相邻像素、当前块的预测值作为网络的输入。本文提出的网络能够提高HEVC中帧间预测的准确性。实验表明,所提出的NNIP算法可以获得平均1.7%(高达8.6%)的BD-rate节省。在未来的研究工作中,将探索NNIP算法在其他帧间模式的效果以及降低网络的计算复杂度。

### 参考文献

- [1] DAI Y, LIU D, WU F. A convolutional neural network approach for post-processing in HEVC intra coding [M]// AMSALEG L, GUÖMUNDSSON G, GURRIN C, et al. MultiMedia Modeling. MMM 2017. Lecture Notes in Computer Science. Cham: Springer, 2017, 10132:28.
- [2] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, Nevada, USA:IEEE, 2016:710.
- [3] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Delving deep into rectifiers surpassing human-level performance on ImageNet classification [C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015:1026.
- [4] BOSSEN F. HM10 Common test conditions and software reference configurations [C]// 12<sup>th</sup> Joint Collaborative Team on Video Coding Meeting. Geneva: [s.n.], 2013:JCTVC-L1100.
- [5] JIA Yangqing, SHELHMER E, CONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding [J]. ACM

- Multimedia, 2014,2:675.
- [6] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. arXiv preprint arXiv:1412.6980,2014.
- [7] BJØNTEGAARD G. Improvements of the BD-PSNR Model, document VCEG-A111, ITU-T Video Coding Experts Group (VCEG) [Z]. Berlin, Germany: Heinrich-Hertz-Institute, 2008.
- [8] SULLIVAN G J, OHM J R, HAN W J, et al. Overview of the high efficiency video coding (HEVC) standard [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2012, 22(12):1649.
- [9] WIEGAND T, SULLIVAN G J, BJØNTEGAARD G, et al. Overview of the H.264/AVC video coding standard [J]. IEEE Transactions on Circuits and Systems for Video, 2006, 13(7):560.
- [10] YIN P, TOURAPIS A M, BOYCE J. Localized weighted prediction for video coding [C]//International Symposium on Circuits and Systems (ISCAS 2005). Kobe, Japan; dblp, 2005, 5:4365.
- [11] JEONG S, PARK H. Offset compensation method for skip mode in hybrid video coding [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2014, 24(10):1825.
- [12] ZHANG Na, LU Yiran, FAN Xiaopeng, et al. Enhanced inter prediction with localized weighted prediction in HEVC [C]//2015 Visual Communications and Image Processing (VCIP). Singapore; IEEE, 2015:1.
- [13] DONG C, LOY C C, HE Kaiming, et al. Learning a deep convolutional network for image super-resolution [C]// European Conference on Computer Vision. Cham; Springer, 2014:184.
- [14] DONG C, DENG Y, LOY C, et al. Compression artifacts reduction by a deep convolutional network [C]// 2005 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile; IEEE, 2015:576.
- [15] WANG Zhongyang, LIU Dong, CHANG Shiyu, et al. D3: Deep dual-domain based fast restoration of JPEG compressed images [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA; IEEE, 2016:2764.

(上接第385页)

## 2.2 中层间接影响因素

中间层的影响因素涉及到老年人自身方面和周围社会环境方面。这里拟做探讨论述如下。

在老年人自身方面,通常来说,受教育程度越高获取知识的能力越强,获得经济收入的渠道越多。老年人若是健康的话,在医疗方面的支出占比相对较低,消费行为多发生在医疗支出方面以外的领域。

社会参与度不仅是整个解释结构模型的起到间接引导作用的因素,而且还是中层影响因素的过渡性因素。城市社区老年人的社会参与度在潜移默化中影响老年人与社会的接触程度,进而影响老年人从社会获得教育的程度以及老年人的情绪和心理健康,同时也将影响其对消费服务和产品的了解程度。

在社会环境方面,有了国家政策的支持,老年人消费市场供给增加,社会参与的积极性提高,在一定程度上催生消费欲望,进而产生消费行为。消费欲望的产生又能够增加老年人进行社会参与的机会。消费环境的安全性是老年人进行消费的有力保障,也是产生消费意愿的助推器。消费环境越安全,老年人的消费行为越有保障,越能激发老年人产生消费行为。

## 2.3 深层根本影响因素

消费渠道的便捷程度是影响老年人消费行为的深层根本因素。人们都倾向于购买消费渠道便捷的产品,消费渠道便捷能够增加老年人的消费欲望;家庭成员的支持则随着老年人的年龄的增长而显得愈发重要,特别是对中高龄老年人来说,家庭成员的支持能够给予其有关消费行为的肯定,获得心理上的满足感,利于心理健康;城市社区老年人的消费习惯一旦养成就较难改变,并且在很大的程度上影响老

年人的消费行为。

## 3 结束语

本文运用解释结构模型分析和探讨了老年人消费行为的影响因素及其关系,将其划为5个不同的层次,3个阶梯,得出相应的解释结构模型,可以看到,不管是从表层直接影响因素中的产品和服务的吸引力、老年人的年龄,还是从深层根本影响因素中的消费习惯、消费是否便捷来看,老年人的实际需要是影响其消费行为的主要因素。因此可以采取相应的措施来满足老年人的实际消费需求。

现如今,网络遍及生活方方面面,可以对有学习能力的老年人就智能产品和网络的使用展开技能传授,在较全面了解老年产品和服务的基础上进行消费,利用计算机智能进一步便利老年人消费。通过网络宣传片向社区老年人的家庭成员讲述其对老年人消费行为和健康的支撑影响作用,并且可以运用大数据根据不同年龄老年人的消费习惯和需求,设计相应的产品和服务,提升老年消费市场的活跃度。

## 参考文献

- [1] FERNÁNDEZ-VILLAVARDE J, KRUEGER D. Consumption over the life cycle: Facts from consumer expenditure survey data [J]. The Review of Economics and Statistics, 2007, 89(3):552.
- [2] 刘勇,李鲁.我国养老消费发展的现状、契机与价值[J].党政论坛,2019(9):42.
- [3] 李涛,徐翔,张旭妍.孤独与消费—来自中国老年人保健消费的经验发现[J].经济研究,2018,53(1):124.
- [4] 张虹,王波.社会基本养老保险对老年人消费影响的实证研究[J].财经问题研究,2014(4):62.
- [5] 杨红娟.老年人消费安全问题的提出及理论建构[J].人口与社会,2018,34(2):7.
- [6] 魏瑾瑞,张睿凌.老龄化、老年家庭消费与补偿消费行为[J].统计研究,2019,36(10):87.