

基于半监督学习的无参考图像质量评价算法

金向东, 桑庆兵*

江南大学人工智能与计算机学院, 江苏 无锡 214122

摘要 为了能够在图像质量评价领域实现自监督学习, 提出一种基于半监督学习的双分支网络训练的无参考图像质量评价算法。它是具有两个分支的训练过程, 其中在一个分支使用少量手工标记数据样本来进行有监督学习, 在另一个分支进行自监督学习来辅助前者训练同一个特征提取器, 自监督学习部分采用几种传统的全参考方法联合为训练样本打上软标签。在 6 个公开的图像数据库中进行大量实验, 结果表明所提算法不仅在合成失真图像数据集上优于目前大多数方法, 而且在真实失真图像数据集上具有良好的泛化性能, 预测结果与人类主观感知表现一致。

关键词 图像质量评价; 特征提取; 自监督学习; 无参考; 联合训练

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP220543

No-Reference Image Quality Assessment Algorithm Based on Semi-Supervised Learning

Jin Xiangdong, Sang Qingbing*

School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, Jiangsu, China

Abstract This paper proposes a no-reference image quality evaluation algorithm based on semi-supervised learning and dual-branch network training to realize self-supervised learning in image quality evaluation. Specifically, it is a training process with two branches in which a small number of hand-labeled data samples are used for supervised learning in one branch. Self-supervised learning is performed in the other branch to assist the former in training the same feature extractor; the self-supervised learning part adopts several traditional full-reference methods to jointly label the training samples with soft labels. Extensive experiments are conducted on six public image databases. The results show that the proposed algorithm outperforms most current methods on the synthetic distorted image datasets and has a good generalization performance on the real distorted image datasets. The predicted results of the proposed algorithm are consistent with human subjective perception performance.

Key words image quality evaluation; feature extraction; self-supervised learning; no reference; joint training

1 引言

近年来, 网络媒体相关产业的蓬勃发展产生了大量的图像与视频。数字图像在获取、压缩、存储到传输等各生命周期阶段都可能发生失真, 从而导致接收到的视觉信息较原本信息存在差距。因此, 迫切需要一种可靠算法去模拟人类视觉, 评估各种图像的质量, 并为最终用户筛选出高质量图像。为此, 国内外学者在图像质量评价领域中进行了大量的研究^[1-5]。通常, 图像质量评价方法根据质量评价过程中训练所需的参考信息量可以分为三类, 分别是全参考、半参考和无参考。虽然全参考图像质量评价(FR-IQA)与半参考图

像质量评价(RR-IQA)方法在现实世界可以实现很好的性能, 但通常情况下一般无法获得参考图像, 导致该类方法存在局限性。因此, 无参考图像质量评价方法显得更为重要, 与此同时, 参考信息的稀缺给无参考图像质量评价方法带来了巨大的挑战。

由于神经网络强大的学习能力, 在图像质量评价领域基于卷积神经网络(CNN)的学习特征方法被提出, 并在图像质量评价中取得了显著的进展。Kang等^[6]首次将卷积神经网络应用在图像质量评价领域, 该网络在没有参考图像的情况下准确预测图像质量, 在LIVE数据集上表现了当时最好的性能。Ma等^[7]提出了一种具有更深层次的网络, 该网络可以同

收稿日期: 2022-01-14; 修回日期: 2022-02-18; 录用日期: 2022-03-30; 网络首发日期: 2022-04-10

通信作者: *sangqb@163.com

时学习失真类型和图像质量。Liu 等^[8]注意到现有 IQA 数据库中训练数据的大小有限,通过标注训练样本的质量等级而不是质量分数来生成大量的训练样本,通过一个孪生神经网络对合成失真的图像进行训练,再将得到的排序信息迁移至图像质量评价任务中。Ye 等^[9]提出一种 opinion free IQA (OF-IQA) 模型,该模型将融合多种全参考算法的综合度量结果作为失真图像的标注分数,再折合为平均主观得分差 (DMOS) 值,旨在解决样本不足的问题。本文借鉴了这一思想,并在其中加入了支持向量回归 (SVR) 模型来综合度量多种全参考算法的结果。Zhang 等^[10]引入了双流网络架构来预测合成图像和真实图像失真。在他们的工作中,对于真实质量预测过程,采用 VGG-16^[11]进行特征提取。Li 等^[12]建议使用来自多面体 ResNet50 特征的统计数据来进行质量预测。近年来,Zhang 等^[13]建议在合成数据库和真实数据库中使用图像对来训练 IQA 模型,用于特征提取的主干是 ResNet-34。虽然这些 IQA 方法在一些数据集上取得了很大的性能改进,但由于训练样本不足(现有数据库的样本从几百幅到几千幅不等),往往存在过拟合和泛化性不足等问题。研究发现,较多 IQA 模型在一个数据集上表现良好,在另一个数据集上却给出了较差的预测。

为了解决训练样本不足问题,人们对不需要手工

标注数据的无监督学习方式越来越感兴趣,而自监督学习是无监督学习方式的一种特殊形式。因此,使用自监督学习作为辅助任务,使特征提取器在少量有标签样本的情况下学习更丰富的视觉信息表达。提出了一种新的自监督学习辅助方法,通过合成失真图像并利用 SVR 拟合多种全参考图像质量评价算法,生成软标签训练样本,基于 SVR 的全参考评分方法比单一全参考方法客观合理;提出了一种使用联合训练网络的策略,将自监督学习融合到图像质量评价少量有标签数据的学习算法的训练目标中,通过两种损失提高特征提取网络的表征能力,使特征提取网络能适应训练数据量少的情况;提出了一种改进的 RepVGG 网络^[14]作为特征提取网络,使得网络在图像提取中能够获取更精确的特征。

2 所提算法内容

所提算法的流程如图 1 所示,模型训练有两个学习阶段。这里定义 $D_T = \{(x, y)\} \subset I \times Y_T$ 作为上分支第一个学习阶段使用的训练集,进行少量手工标注数据的学习,其中 $x \in I$ 是大小为 N_T 的标签集 Y_T 中标签为 y 的图像。此外,定义 $D_A = \{(x, y)\} \subset I \times Y_A$ 作为下分支第二个学习阶段的训练集,进行自监督学习。这里的标签集 Y_T 和 Y_A 是分离互不影响的。

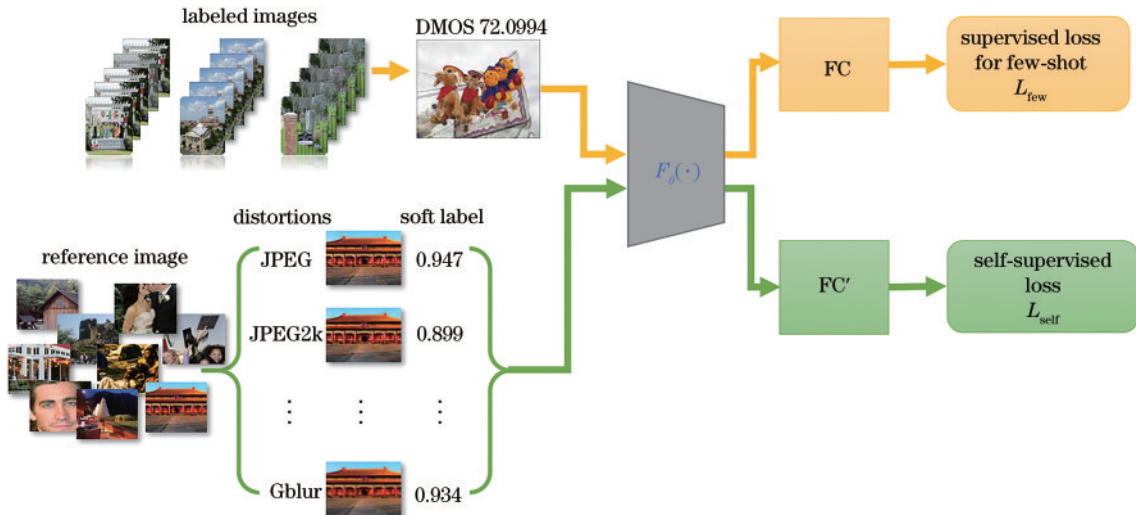


图 1 所提算法的流程

Fig. 1 Flowchart of the proposed algorithm

2.1 特征提取网络

特征提取网络的主要组成部分是一个特征提取器 $F_\theta(\cdot)$,它是一个参数为 θ 的卷积网络。对于给定的图像 x ,特征提取器将输出一个 n 维的特征 $F_\theta(x)$ 。其中特征提取网络部分采用改进后的 RepVGG,该网络仅由 3×3 卷积和激活函数组成,包括 5 个阶段,如图 2 所示。采用的 5 个阶段所含的层数分别为 1、4、6、16、1。

RepVGG 主要的思路包括:把 ResNet 中的多分支

思想应用到 VGG 网络中,在 VGG 网络块中加入残差分支和残差连接;在模型推理阶段,通过融合策略将所有的网络层都转换为 3×3 卷积,以便于网络的部署和加速测试。图 3 展示了 RepVGG 网络与 ResNet 的对比。正是因为 ResNet 解决了梯度消失问题,网络更易于收敛,而 RepVGG 的训练网络借鉴了这一方法,但不同的是残差块并没有像 ResNet 一样跨层。整个特征提取网络包括两种残差结构:一种仅仅包含 1×1 卷




图 2 特征提取网络的结构

Fig. 2 Structure of feature extraction network

积残差分支;第二种含有 1×1 卷积残差结构、 3×3 卷积残差结构和残差连接结构。残差结构的多分支相当于给网络提供了多条梯度流动的路径。RepVGG的推理网络作为推理阶段的网络,整个网络仅有 3×3 卷积与ReLU激活函数,这提升了模型的推理速度。

网络训练和网络推理阶段使用不同的网络架构,训练阶段更关注精度,推理阶段更关注速度。训练时的网络是残差连接和 1×1 卷积分支构建的,这些分支能够通过结构化的再参数化移除。训练完成后,通过简单的代数执行变换,残差连接分支能被视作退化后的 1×1 卷积, 1×1 卷积可被视为退化后的 3×3 卷积,这样就能使用原来 3×3 卷积核、残差连接、 1×1 分支及批归一化(BN)层已经训练好的参数来构造一个 3×3 的核函数结构,转换后的模型只有 3×3 卷积层的堆叠,用于测试和部署,这大大提升了测试速度。

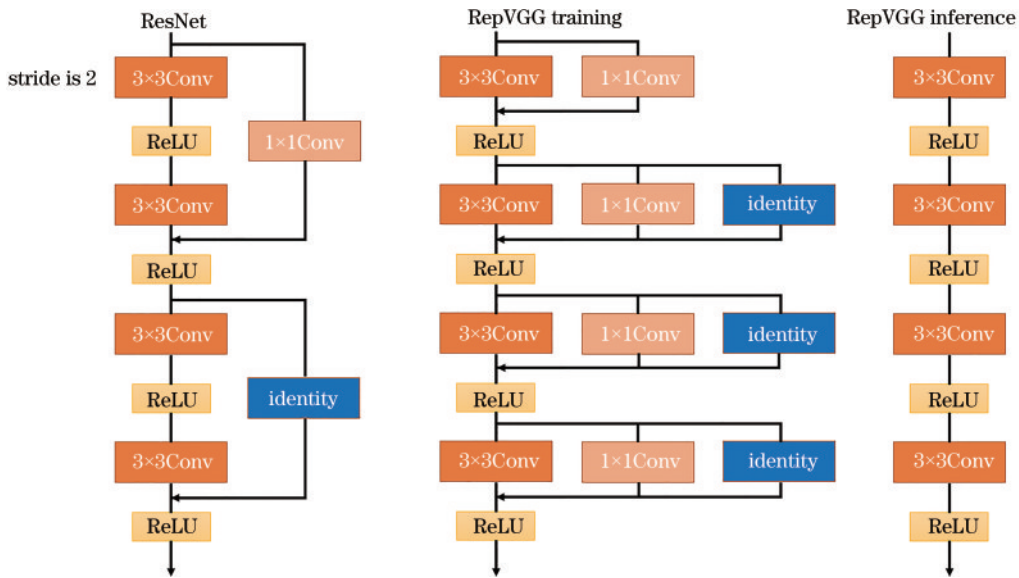


图 3 ResNet 和 RepVGG 的部分架构示意图

Fig. 3 Schematic of part architecture of ResNet and RepVGG

其中激活函数由原来的ReLU改为P-ReLU^[15],它是一种ReLU的改进,解决在负数区域内ReLU响应为零的问题,表达式为

$$P-ReLU(y_i) = \begin{cases} y_i, & y_i \geq 0 \\ a_i y_i, & y_i < 0 \end{cases}, \quad (1)$$

式中: y_i 表示第*i*个信道的非线性激活P-ReLU的输入; a_i 表示负数区域的斜率系数。P-ReLU作为激活函数能有效兼顾正负响应,有效提取低层次信息。图4展示了ReLU与P-ReLU的区别,对于P-ReLU,负数部分斜率系数为*a*,它不是恒定的,是自适应学习的。

在特征提取网络之后接3层全连接层作为回归网络,结构如表1所示,其中(*m*,*n*)分别表示该全连接层的输入节点数与输出节点数。




图 4 ReLU 与 P-ReLU 的对比

Fig. 4 Comparison between ReLU and P-ReLU

表 1 质量分数回归网络

Table 1 Quality score regression network

Name	Layer
FC1	(1000, 1024)
FC2	(1024, 512)
FC3	(512, 1)

2.2 自监督学习辅助任务

训练深度神经网络时往往需要海量数据,因为训练数据不足容易导致模型发生过拟合和泛化能力不足的问题。如何使特征提取器在训练数据量较少的情况下学习到更多的图像特征成了主要问题,这里采用自监督学习来改进当前图像质量评价中对少量样本量的学习过程。

在自监督学习任务中,对收集到的参考图像使用不同的失真方法生成失真图像,使用 5 种全参考图像质量评价方法对每张失真图像进行质量评价,在对每张图像获得 5 个质量分数后,再在已训练好的 SVR 模型上拟合分数,其结果作为数据集的软标签。通过这

些工作,来拓展特征提取器 $F_{\theta}(\cdot)$ 的训练,最终取得的结果显示这能鼓励网络学习到更丰富和准确的图像特征。使用的 SVR 模型是在 LIVE 数据集^[16]上进行训练和验证的,如图 5 所示,首先通过 5 种全参考图像质量评价算法对 LIVE 数据集图像进行评分,得到对应每张图像 5 个全参考评价分数,最后通过 SVR 拟合 5 个分数,预测出其对应的软标签 y 。其中 5 种全参考图像质量评价方法分别为 structural similarity index (SSIM)^[17]、feature similarity index method (FSIMc)^[18]、visual saliency-induced index (VSI)^[19]、gradient magnitude similarity deviation (GMSD)^[20]、superpixel-based similarity index (SPSIM)^[21]。

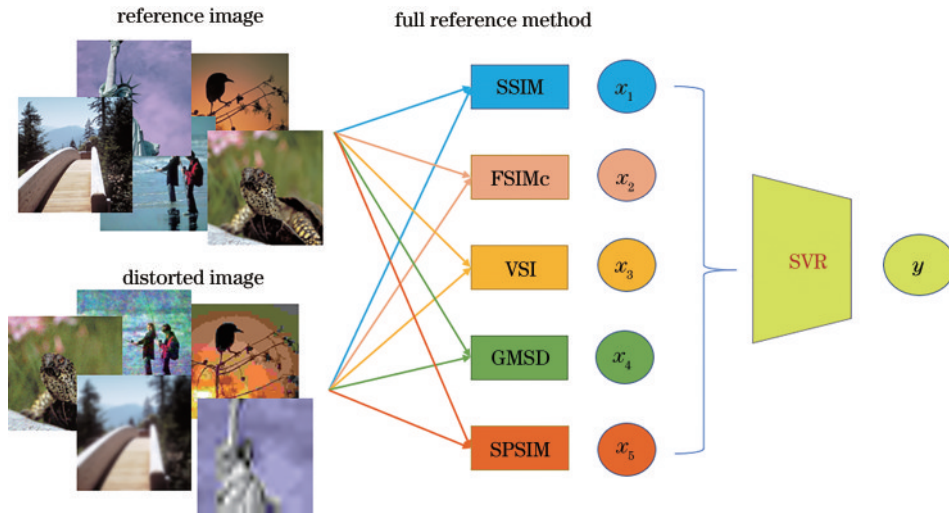


图 5 自监督学习部分软标签的生成

Fig. 5 Soft label generation in self-supervised learning part

在 LIVE 数据集中,划分 80% 作为训练集,进行大量对比实验,最终训练得到的 SVR 模型可以通过 5 个全参考图像质量评价分数高度拟合 DMOS 值,并且获得了更好的效果。表 2 展示了 SVR 模型预测与 5 种全参

考图像质量评价算法的对比。结果表明,SVR 比 5 种全参考图像质量评价取得了更高的 Pearson 线性相关系数 (PLCC) 和 Spearman 等级相关系数 (SROCC),证明了 SVR 拟合评分的有效性和准确性。

表 2 SVR 模型预测与 5 种全参考图像质量评价算法的对比

Table 2 Comparison of SVR model prediction and five full-reference image quality evaluation algorithms

Dataset	Parameter	SSIM	FSIMc	GMSD	VSI	SPSIM	Proposed algorithm
LIVE	SROCC	0.948	0.965	0.960	0.952	0.962	0.986
	PLCC	0.945	0.965	0.960	0.943	0.960	0.963

无标签参考图像的失真生成程度由生成失真时所设置的失真参数确定,为保证失真图像的失真度的随机性,将失真参数设置为随机化。不同类型的失真图像生成方法各有不同,本文中的 6 种合成失真均在 MATLAB 软件中生成。利用网络采集到的 400 张无标签参考图像,生成 JPEG 失真、JPEG2k 失真、Gblur 失真、WN 失真、运动模糊失真、椒盐噪声失真 6 种失真类型图像各 10 张,共计 24000 张图像。

在有参考图像对应失真图像时,基于全参考图像质量评价的算法在图像预测中能够取得很好的效果,

考虑到自监督任务中图像软标签的准确性和综合性,这里使用 SSIM、FSIMc、VSI、GMSD、SPSIM 5 种全参考图像质量评价方法对生成的 24000 张图像进行评分。

2.3 损失函数

在上分支学习中采用均方误差 ((MSE)) 损失函数,表达式为

$$L_{\text{few}} = \sum_{j=1}^J (y_j - y_j^p)^2 \quad (2)$$

在下分支自监督学习中使用 Log-Cosh 损失作为

损失函数,表达式为

$$L_{\text{self}} = \sum_{j=1}^J \log [\cosh (y_j - y_j^p)], \quad (3)$$

式中: y_j 为样本标签; y_j^p 为训练网络时的预测分数。训练损失的自监督损失 L_{self} 不依赖类标签, 可以很容易地扩展它, 也可以从其他未标记的数据中学习。通过训练特征提取器 $F_{\theta}(\cdot)$, 将额外的未标记图像的自监督损失最小化, 适应多种失真图像类型的情况。这也可以看作是一种半监督的训练方法, 因为它不要求额外的数据与有标签数据集相同, 因此能够更灵活地处理无标签参考图像的来源, 具有良好的拓展性。

表 3 在各数据集图像质量评价的对比

Table 3 Comparison of image quality assessment on each dataset

Dataset	Number of referenced images	Number of distorted images	Evaluation parameter	Parameter range
LIVE	29	779	DMOS	[0,100]
CSIQ	30	866	DMOS	[0,1]
TID2008	25	1700	MOS	[0,9]
TID2013	25	3000	MOS	[0,9]
Challenge		1169	MOS	[0,100]
KonIQ-10k		10073	MOS	[0,5]

3.2 图像质量评价指标

在图像质量评价领域, 常用 PLCC 和 SROCC 来评估图像质量评价算法的性能。PLCC 能够表示出两组数据之间的相关性, 在图像质量评价中使用预测值与真实值计算该系数, 能够反映预测的准确性。PLCC 定义为

$$C_{\text{PLCC}} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (4)$$

式中: x_i 为第 i 张图像的主观真实分数; y_i 为第 i 张图像的算法预测分数; \bar{x} 和 \bar{y} 分别为这 n 张图像的主观真实分数和算法预测分数的均值。SROCC 能够表示出两组数据之间的单调性, 在图像质量评价中使用预测值与真实值计算该系数, 能够反映预测的相关性。SROCC 定义为

$$C_{\text{SROCC}} = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (y_i - x_i)^2. \quad (5)$$

3.3 实验结果与分析

人类观看图像依赖于人眼对图像信息的捕获和大脑对图像信息的分析整合, 对图像质量的判断受到多种因素的影响, 综合多种因素指标才能符合人类视觉系统特性。为了验证算法是否符合人类视觉系统特性, 使用两种类型的统计分析方法: 一是用 PLCC 评估预测的准确性; 二是用 SROCC 评估预测的单调性。如果模型附加某些非线性变换, 会造成 PLCC 性能变

3 实 验

3.1 图像质量评价数据库

选择常用的图像质量评价数据集: LIVE^[16]、TID2008^[22]、TID2013^[23]、CSIQ^[24]、LIVE in the wild image quality challenge database (Challenge)^[25] 和 KonIQ-10k^[26] 来比较所提方法与其他图像质量评价方法的性能。其中 Challenge 和 KonIQ-10k 为自然失真数据集, 其他均为人工模拟失真数据集。各数据集的详细情况如表 3 所示。评价指标 MOS 表示平均主观得分, MOS 值越大说明图片质量越高; DMOS 是平均主观得分差, 表示人对参考图像和失真图像评价得分的差异, DMOS 值越小说明图片质量越高。

好, 但是 SROCC 性能不会被影响, 因此 SROCC 被认为是最好的非线性相关指标。数据库中的数据标签是人类来评分的, PLCC 和 SROCC 能说明预测数据与原始数据的相关性。PLCC 和 SROCC 的绝对值越大就表示算法越接近于人类的主观感知。

对于每个数据集, 划分 80% 的图像用于训练, 剩下部分用于测试。对于合成图像数据库 LIVE 和 CSIQ, 根据参考图像进行分割, 以避免内容重叠。如表 4 所示, 对所提算法和具有代表性的 MLV^[27]、A-D^[28]、RISE^[29]、DIQA^[30]、DB-CNN^[10] 5 种评价模型进行比较。所提算法的 SROCC 和 PLCC 指标优于其他无参考方法, 这表明所提算法较为优秀, 具有更接近人类的主观感知。与在 TID2013 数据集取得最佳效果的 RISE 方法相比, 所提算法在其他人工合成图像库上均优于它, 表明所提算法具有更高的泛化能力。结果表明, 联合监督学习与自监督学习的这种半监督学习方法能够有助于感知图像质量并取得不错的效果, 展示出所提算法的有效性。

图 6 展示所提算法在 4 个合成图像数据集 (LIVE、CSIQ、TID2008 和 TID2013) 上的预测散点图。

另外还有一些方法在 LIVE 数据集上取得较好的效果后, 选择将重点放在了自然失真数据集研究上, 所以所提算法在自然失真数据集上与它们进行对比。表 5 展示所提算法与 4 种优秀的无参考图像质量评价算法在自然失真数据集上的性能对比。比较的方法包括 HOSA^[31]、WaDIQaM-NR^[32]、PQR^[33]、SFA^[12]。值

表 4 在人工模拟数据集上不同算法的性能比较

Table 4 Performance comparison of different algorithms on artificial simulation datasets

Dataset	Parameter	MLV	A-D	RISE	DIQA	DB-CNN	Proposed algorithm
LIVE	SROCC	0.931	0.968	0.949	0.970	0.968	0.983
	PLCC	0.943	0.973	0.962	0.972	0.971	0.979
CSIQ	SROCC	0.925		0.922	0.843	0.946	0.957
	PLCC	0.949		0.942	0.868	0.959	0.953
TID2008	SROCC	0.855	0.865				0.928
	PLCC	0.858	0.869				0.939
TID2013	SROCC	0.879	0.812	0.934	0.844	0.816	0.926
	PLCC	0.883	0.845	0.942	0.880	0.865	0.934

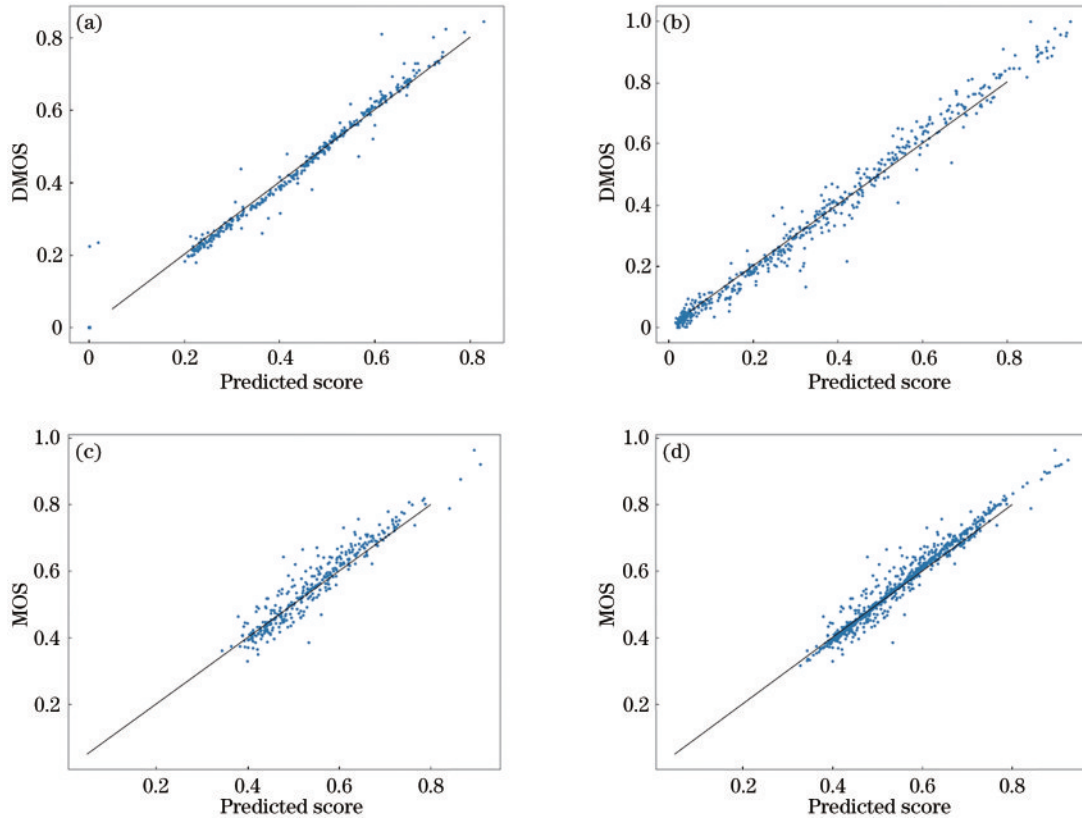


图 6 所提算法在各数据集上的预测结果的散点图。(a)LIVE数据集;(b)CSIQ数据集;(c)TID2008数据集;(d)TID2013数据集

Fig. 6 Scatter plot of prediction results of the proposed algorithm on each dataset. (a) LIVE dataset; (b) CSIQ dataset; (c) TID2008 dataset; (d) TID2013 dataset

表 5 在自然失真数据集上不同算法的性能对比

Table 5 Performance comparison of different algorithms on natural distortion datasets

Algorithm	Challenge		KonIQ-10k	
	SROCC	PLCC	SROCC	PLCC
HOSA	0.640	0.678	0.671	0.694
WaDIQaM-NR	0.671	0.680	0.797	0.805
PQR	0.857	0.882	0.880	0.884
SFA	0.812	0.833	0.856	0.872
Proposed algorithm	0.871	0.863	0.893	0.845

值得注意的是:与同样利用骨干分类网络提取深度语义特征的PQR和SFA相比,所提算法在Challenge数据

集的SROCC上优于PQR,在KonIQ-10k数据集的SROCC上优于SFA;相比PQR和SFA所使用的ResNet-50深度网络模型,所提算法使用的RepVGG作为特征提取网络更加优秀,它使用结构重参数化“复兴”VGG式单路架构,一直进行 3×3 卷积,在速度和性能上均超过ResNet-50深度网络模型。在公平的训练设定下,同精度的RepVGG速度是ResNet-50的183%。大量实验表明:所提算法不仅能在合成数据集上取得极佳的效果,在真实失真数据集上也能达到不错的结果,并且速度与性能优于当前主流的一些方法。

3.4 消融实验

为了进一步研究所提算法的有效性,在LIVE数据集和Challenge数据集上进行消融研究。基线方法

只使用所提网络结构中的上分支在 LIVE 数据集上训练所提算法,然后进行测试。值得注意的是,基线方法和所提算法有相同数量的网络参数,但由两种不同的优化方法训练。表 6 为消融实验结果。可以看到:所提算法具有更好的性能,表明添加下分支自监督学习辅助任务后可以在不改变网络结构的情况下提高 NR-IQA 模型的性能,在 LIVE 数据集上 SROCC 和 PLCC 分别增加了 1.6 个百分点和 2.2 个百分点,在 Challenge 数据集上 SROCC 和 PLCC 分别增加了 3.0 个百分点和 4.1 个百分点。结果验证了这种联合监督学习与自监督学习的半监督学习任务以及修改激活函数后可以提升特征提取网络适应不同数据集的泛化能力。

表 6 消融实验结果
Table 6 Ablation experimental results

Module	LIVE		Challenge	
	SROCC	PLCC	SROCC	PLCC
RepVGG+ReLU	0.967	0.957	0.841	0.822
RepVGG+P-ReLU	0.969	0.962	0.845	0.835
RepVGG+ReLU+self	0.981	0.975	0.869	0.857
RepVGG+P-ReLU+self(ours)	0.983	0.979	0.871	0.863

4 结 论

提出了一个新的自监督学习策略方法,结合多种失真算法并通过 SVR 模型拟合几种主流的全参考评价方法,实现自监督学习,以克服在图像质量评价任务中数据不足导致的模型过拟合问题,并通过联合双分支的策略共同训练一个特征提取器。在图像质量评价领域几个主流数据集上进行了大量的实验。实验结果表明:增加自监督学习后显著改善了少量训练数据下模型提取特征的性能,通过双分支共同训练,所采用的特征提取网络达到了良好的能力,进一步验证了将自监督学习运用在图像质量评价算法中进行联合监督学习与自监督学习的这种半监督学习方法的有效性。所提模型具有优异的性能和较强的泛化能力,同时所使用的算法也具有广泛的应用场景和研究价值。其中自监督学习部分还可以利用多种失真算法联合失真来实现数据的扩充,后续工作可以此展开。

参 考 文 献

[1] Kim J, Lee S. Deep learning of human visual sensitivity in image quality assessment framework[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1969-1977.

[2] 马琼, 李通, 赵巨峰, 等. 使用局部视觉显著分析的红外图像增强[J]. 光学技术, 2021, 47(5): 601-607.
Ma Q, Li T, Zhao J F, et al. Infrared image

enhancement using visual saliency analysis within local window[J]. Optical Technique, 2021, 47(5): 601-607.

- [3] 卢鹏, 刘楷贇, 邹国良, 等. 基于多特征融合和卷积神经网络的无参考图像质量评价[J]. 液晶与显示, 2022, 37(1): 66-76.
Lu P, Liu K Y, Zou G L, et al. No reference image quality assessment based on fusion of multiple features and convolutional neural network[J]. Chinese Journal of Liquid Crystals and Displays, 2022, 37(1): 66-76.
- [4] 叶蒙蒙, 胡晋滨, 王雪津, 等. 基于双目神经元响应的无参考立体图像质量评价[J]. 激光与光电子学进展, 2021, 58(24): 2410007.
Ye M M, Hu J B, Wang X J, et al. No-reference stereoscopic image quality assessment based on binocular neuron response[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2410007.
- [5] 沈飞鹏, 朱彤, 张赫男, 等. 基于显著性目标分类的无参考模糊图像质量评价[J]. 激光与光电子学进展, 2021, 58(22): 2210015.
Shen F P, Zhu T, Zhang H N, et al. Non-reference blur image quality evaluation based on saliency object classification [J]. Laser & Optoelectronics Progress, 2021, 58(22): 2210015.
- [6] Kang L, Ye P, Li Y, et al. Convolutional neural networks for no-reference image quality assessment[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 1733-1740.
- [7] Ma K D, Liu W T, Zhang K, et al. End-to-end blind image quality assessment using deep neural networks[J]. IEEE Transactions on Image Processing, 2018, 27(3): 1202-1213.
- [8] Liu X L, van de Weijer J, Bagdanov A D. RankIQA: learning from rankings for no-reference image quality assessment[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 1040-1049.
- [9] Ye P, Kumar J, Doermann D. Beyond human opinion scores: blind image quality assessment based on synthetic scores[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 4241-4248.
- [10] Zhang W X, Ma K D, Yan J, et al. Blind image quality assessment using a deep bilinear convolutional neural network[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(1): 36-47.
- [11] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-02-03]. <https://arxiv.org/abs/1409.1556>.
- [12] Li D Q, Jiang T T, Lin W S, et al. Which has better visual quality: the clear blue sky or a blurry animal? [J]. IEEE Transactions on Multimedia, 2019, 21(5): 1221-1234.
- [13] Zhang W X, Ma K D, Zhai G T, et al. Learning to blindly assess image quality in the laboratory and wild [C]//2020 IEEE International Conference on Image Processing, October 25-28, 2020, Abu Dhabi, United

- Arab Emirates. New York: IEEE Press, 2020: 111-115.
- [14] Ding X H, Zhang X Y, Ma N N, et al. RepVGG: making VGG-style ConvNets great again[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13728-13737.
- [15] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1026-1034.
- [16] Sheikh H R, Sabir M F, Bovik A C. A statistical evaluation of recent full reference image quality assessment algorithms[J]. IEEE Transactions on Image Processing, 2006, 15(11): 3440-3451.
- [17] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [18] Zhang L, Zhang L, Mou X Q, et al. FSIM: a feature similarity index for image quality assessment[J]. IEEE Transactions on Image Processing, 2011, 20(8): 2378-2386.
- [19] Zhang L, Shen Y, Li H Y. VSI: a visual saliency-induced index for perceptual image quality assessment[J]. IEEE Transactions on Image Processing, 2014, 23(10): 4270-4281.
- [20] Xue W F, Zhang L, Mou X Q, et al. Gradient magnitude similarity deviation: a highly efficient perceptual image quality index[J]. IEEE Transactions on Image Processing, 2014, 23(2): 684-695.
- [21] Sun W, Liao Q M, Xue J H, et al. SPSIM: a superpixel-based similarity index for full-reference image quality assessment[J]. IEEE Transactions on Image Processing, 2018, 27(9): 4232-4244.
- [22] Ponomarenko N, Lukin V, Zelensky A, et al. TID2008: a database for evaluation of full-reference visual quality assessment metrics[J]. Advances of Modern Radioelectronics, 2009, 10(4): 30-45.
- [23] Ponomarenko N, Jin L N, Ieremeiev O, et al. Image database TID2013: peculiarities, results and perspectives [J]. Signal Processing: Image Communication, 2015, 30: 57-77.
- [24] Larson E C, Chandler D M. Most apparent distortion: full-reference image quality assessment and the role of strategy[J]. Journal of Electronic Imaging, 2010, 19(1): 011006.
- [25] Ghadiyaram D, Bovik A C. Massive online crowdsourced study of subjective and objective picture quality[J]. IEEE Transactions on Image Processing, 2016, 25(1): 372-387.
- [26] Hosu V, Lin H H, Sziranyi T, et al. KonIQ-10k: an ecologically valid database for deep learning of blind image quality assessment[J]. IEEE Transactions on Image Processing, 2020, 29: 4041-4056.
- [27] Bahrami K, Kot A C. A fast approach for no-reference image sharpness assessment based on maximum local variation[J]. IEEE Signal Processing Letters, 2014, 21(6): 751-755.
- [28] Chen D Q, Wang Y Z, Gao W. No-reference image quality assessment: an attention driven approach[J]. IEEE Transactions on Image Processing, 2020, 29: 6496-6506.
- [29] Li L D, Xia W H, Lin W S, et al. No-reference and robust image sharpness evaluation based on multiscale spatial and spectral features[J]. IEEE Transactions on Multimedia, 2017, 19(5): 1030-1040.
- [30] Li H Y, Zhu F, Qiu J H. CG-DIQA: no-reference document image quality assessment based on character gradient[C]//2018 24th International Conference on Pattern Recognition (ICPR), August 20-24, 2018, Beijing, China. New York: IEEE Press, 2018: 3622-3626.
- [31] Xu J T, Ye P, Li Q H, et al. Blind image quality assessment based on high order statistics aggregation[J]. IEEE Transactions on Image Processing, 2016, 25(9): 4444-4457.
- [32] Bosse S, Maniry D, Müller K R, et al. Deep neural networks for no-reference and full-reference image quality assessment[J]. IEEE Transactions on Image Processing, 2018, 27(1): 206-219.
- [33] Zeng H, Zhang L, Bovik A C. A probabilistic quality representation approach to deep blind image quality prediction[EB/OL]. (2017-08-28) [2021-02-05]. <https://arxiv.org/abs/1708.08190>.