

卷积神经网络结合深度森林的无参考图像质量评价

陈寅栋¹, 李朝锋², 桑庆兵^{1*}

¹江南大学物联网工程学院, 江苏 无锡 214122;

²上海海事大学物流科学与工程研究院, 上海 200135

摘要 提出了一种新的卷积神经网络与深度回归森林结合的无参考图像质量评价方法。该方法对原始图像进行局部对比度归一化处理, 采用卷积神经网络提取图像质量的判别特征, 最后利用深度回归森林预测图像质量。该方法无须手工设计图像特征, 简化了图像的预处理过程。较少的卷积层数有利于减少网络的训练时间。使用深度策略对回归森林进行集成, 提高了单一森林的预测精度。基于 LIVE 数据库与 TID2008 数据库的实验结果表明, 该方法能很好地预测图像质量, 并具有良好的泛化性能与较高的准确率, 尤其在 JPEG2000 压缩、高斯模糊和白噪声等 3 种失真类型上均表现出了良好的性能。

关键词 图像处理; 无参考图像质量评价; 卷积神经网络; 回归森林; 局部对比度归一化

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.111003

Quality Assessment Without Reference Images Based on Convolutional Neural Network and Deep Forest

Chen Yindong¹, Li Chaofeng², Sang Qingbing^{1*}

¹ School of Internet of Things Engineering, Jiangnan University, Wuxi, Jiangsu 214122, China;

² Institute of Logistics Science & Engineering, Shanghai Maritime University, Shanghai 200135, China

Abstract This paper proposes a new quality assessment method without reference images based on the convolutional neural network (CNN) and deep regression forest. First, this method performs a local contrast normalization on the original images. Second, it subsequently uses CNN to extract the discriminant features of the image quality. Finally, it utilizes the deep regression forest to predict the image quality. The method does not require any manual features, which simplifies the process of image preprocessing. In addition, fewer convolution layers are beneficial to reduce the training time of the network. The application of deep strategy to integrate the regression forests improves the prediction accuracy of a single forest. On the LIVE and TID2008 databases, the experimental results show that the proposed method can predict the image quality well and has a good generalization performance with high accuracy. The proposed method achieves a state-of-the-art performance, especially in JPEG2000, Gaussian blur and white noise distortions.

Key words image processing; quality assessment without reference images; convolutional neural network; regression forest; local contrast normalization

OCIS codes 100.2000; 110.3000

1 引言

随着数字成像设备的广泛使用和网络工具的快速发展, 图像作为信息的载体发挥着越来越重要的作用。但是, 在采集、存储、传输等过程中, 许多因素

会引起图像的失真, 降低图像质量, 从而影响后续处理的结果。因此, 图像质量评价^[1]是图像领域一个非常重要的研究方向。

图像质量评价主要分为主观方法与客观方法^[2]。主观方法通常是依靠大量观察者给出具体评

收稿日期: 2018-11-23; 修回日期: 2018-11-27; 录用日期: 2018-12-25

基金项目: 国家自然科学基金(61771223)、江苏省自然科学基金(BK20171142)

* E-mail: sangqb@163.com

分,然后采用统计方法(取均值等)得出图像质量分数,该方法长久以来都被认为是对图像质量进行评价的最佳方法^[2]。但是在现实应用中,主观方法存在费时费力且容易受到环境因素影响等缺点。客观方法改善了这种缺点,是现今研究的主流方向。根据有无原始无失真图像介入评价过程,客观方法可以分为全参考、半参考和无参考等3种图像质量评价方法。全参考与半参考方法需要用到原始无失真图像的全部或部分信息^[3-5],具有较好的主观一致性。但是在现实生活中,完全无失真图像很难得到,大多数图像都有一定程度的失真。无参考方法在评价图像的质量时不需要考虑其对应的无失真图像,因此现在的研究方向多集中于无参考方法。

无参考图像质量评价算法近年来取得了一定的进展。Moorthy等^[6]提出了一种基于支持向量机先分类后回归的两步评价框架,采用小波变换分解图像,并结合高斯尺度混合模型对小波系数进行拟合;Mittal等^[7]提出了一种无参考的空间域图像质量评估(BRISQUE)算法,该方法根据亮度系数归一化分布从空域中提取特征,大大缩短了计算时间;Saad等^[8]采用广义高斯模型拟合离散余弦变换(DCT)系数,采用贝叶斯概率模型评价图像质量;Li等^[9-10]提出了广义回归神经网络(GRNN)模型,该方法用人工提取的图像感知特征训练广义回归神经网络,而后又在此基础上通过将相位一致最大矩和最小矩与灰度梯度共生矩阵相结合提取了更有效的图像质量特征。

近年来,卷积神经网络等深度学习技术在图像分类、识别等领域取得了很大的成功,基于深度学习方法的图像质量评价方法也得到了广泛的应用。Kang等^[11]对原始图像进行不重叠分块以及局部对比度归一化,通过卷积神经网络(CNN)提取出图像特征并预测了图像分数;Wu等^[12]在Kang等^[11]的网络结构基础上增加了均值池化与方差池化,最后使用支持向量机预测了图像质量。

卷积神经网络的特点在于将特征提取和回归(或分类)相结合,最后的回归(或分类)采用简单的线性函数输出结果,而忽略了数值间的关系。回归森林算法通过建立多棵回归树并综合每棵回归树的结果,通过决策表法得出最后的预测结果,从而获得比单棵树更好的预测结果。据此,本文提出了一种基于CNN与回归森林的图像质量评价算法,主要分为两个部分:1)使用CNN提取图像块特征;2)使用深度集成的回归森林算法预测图像质量。

2 卷积神经网络提取图像特征

2.1 局部对比度归一化

使用CNN进行模型训练时,对比度归一化不仅能够有效地缓解神经元的过拟合问题,而且能减少光照和对比度变化对网络带来的影响。在无参考图像质量评价问题中,应在局部应用对比度归一化,例如文献^[7,13]使用局部对比度归一化对图像进行预处理。首先对图片进行类似文献^[7]的局部对比度归一化操作。假设位置 (i,j) 处的像素点强度值为 $I(i,j)$,则其归一化值 $\hat{I}(i,j)$ 可表示为

$$\hat{I}(i,j) = \frac{I(i,j) - \mu(i,j)}{\sigma(i,j) + C}, \quad (1)$$

式中: C 为常数; $\mu(i,j)$ 与 $\sigma(i,j)$ 分别代表灰度图像均值与方差,即

$$\mu(i,j) = \sum_{p=-P}^P \sum_{q=-Q}^Q \omega_{p,q} I_{p,q}(i,j), \quad (2)$$

$$\sigma(i,j) =$$

$$\sqrt{\sum_{p=-P}^P \sum_{q=-Q}^Q \omega_{p,q} [I_{p,q}(i,j) - \mu(i,j)]^2}, \quad (3)$$

式中: $\omega_{p,q}$ 为二维中心对称的高斯加权函数; p 和 q 为高斯窗口的长和宽; P 和 Q 表示局部归一化窗口大小。文献^[7]指出,远小于图片的归一化窗口能提升整个模型性能,因此本文在实际处理时选择 $P=Q=3$ 作为局部归一化的窗口大小。值得注意的是,使用该方法进行局部对比度归一化后,每个像素可能具有不同的局部均值与方差。

2.2 卷积神经网络模型

卷积神经网络一般包含以下6个部分:输入、卷积、激活、池化、全连接和输出。对于图像质量评价问题,卷积操作用于提取图像局部特征;池化操作用于压缩卷积获得的特征图,简化网络计算复杂度并提取主要特征;全连接用于输出最后的结果。

相比于传统的sigmoid或者tanh激活函数,本文使用修正线性单元(ReLU)作为卷积神经网络中的激活函数。文献^[11]在深层CNN中证明,使用ReLU比tanh单元训练网络速度快。ReLU采用简单的非线性形式,将阈值函数应用于输入,令 g 、 ω_i 、 α_i 分别为ReLU的输出、第 i 层的权值和输入,则有

$$g = \max(0, \sum_i \omega_i \alpha_i). \quad (4)$$

本文CNN结构如图1所示,包含3个卷积与池化层和2个全连接层,图中conv为卷积层,pool

为池化层,fc为全连接层。输入层接收经过局部对比度归一化后的 72×72 大小的图像块,使用 3×3 大小的卷积核进行卷积操作,经过第一个卷积层后得到64个 72×72 大小的特征图,然后进行最大值池化,池化核大小为 2×2 ,步长为2,输出64个 36×36 的特征图。依次进行卷积、池化操作,然后连接2




图1 CNN网络结构

Fig. 1 Architecture of CNN

3 深度集成森林

3.1 回归森林

回归森林是由 N 棵回归树组成的森林,每棵树使用方均根误差(RMSE)作为分裂准则。对于第 k 棵回归树,将任一叶节点 $R_m^{(k)}$ 的输出值 $c_m^{(k)}$ 定义为该节点上所有输入实例 x_t 对应的输出 y_t 的均值,即

$$c_m^{(k)} = \text{avg}(y_t | x_t \in R_m^{(k)}), \quad (5)$$

对于第 r 个变量 $x^{(r)}$ 和切分点 s ,定义2个区域, x 表示区域中的变量:

$$R_1(r, s) = \{x | x^{(r)} \leq s\}, \quad (6)$$

$$R_2(r, s) = \{x | x^{(r)} > s\}. \quad (7)$$

当 r 和 s 固定时,目标函数为

$$L_j = \min_{r,s} [\min_{c_1} \sum_{x_t \in R_1(r,s)} (y_t - c_1)^2 + \min_{c_2} \sum_{x_t \in R_2(r,s)} (y_t - c_2)^2], \quad (8)$$

式中: c_1 和 c_2 为区间上的平均值,即

$$c_1 = \text{avg}[y_t | x_t \in R_1(r, s)], \quad (9)$$

$$c_2 = \text{avg}[y_t | x_t \in R_2(r, s)], \quad (10)$$

故当 m_k 是回归树深度时,整个回归森林的输出即为

$$F = \{c_{m_1}^{(1)}, c_{m_2}^{(2)}, \dots, c_{m_k}^{(k)}\}, k = N. \quad (11)$$

3.2 集成策略

最常见的集成学习方式是通过某种集成策略将多个弱学习器组合成一个强学习器,以此获得更好的性能。比如文献[14]中基于阈值选择的方法对支持向量机(SVM)进行集成;文献[15]提出了基于随机森林,使用深度策略结合的方法。假设存在3个弱学习器M1、M2和M3,分别对3组样本进行预

个全连接层,分别有1024和1个神经结点。将最后一个全连接层的输出作为模型对图像块提取的特征。由于在训练过程中,随着迭代次数增多,过多的全连接节点会导致模型过拟合,因此在第1个全连接后添加了dropout层,按照50%的概率随机抛弃节点以防止过拟合。

测,若3个学习器的预测精度都较高且对于不同样本有着不同的预测结果,那么集成后的模型性能能够得到提升。而假如3个学习器的预测精度较高,但是对不同样本的预测结果完全相同或者学习器本身预测精度较低,则集成模型性能无法得到显著提升。由此可得:个体学习器之间的差异性以及个体学习器本身的性能决定了集成效果的好坏^[16]。个体学习器的差异性主要由训练数据的差异性决定,产生这种差异的方法一般有2种:基于特征集的方法和基于数据的方法^[17]。前者通过一定的策略选取特征子集来获得差异性,后者采用随机选取数据方法获得集成个体间的差异性。本文通过将2类集成学习算法结合,提出了深度集成的回归森林算法:1)通过基于特征集的方法选择不同的特征组合;2)通过基于数据技术的方式进一步选择特征,增加特征之间的差异性;3)使用回归森林建立预测模型。

3.3 深度回归森林模型

深度回归森林^[15]由多层回归森林组成,其深度由前后2层森林的预测误差决定。图2为深度回归森林结构。

给定数据集 y 与阈值 e ,将 y 作为第一层回归森林的输入,并将其输出值作为后一层回归森林的输入。令 O_{pre} 与 O_{aft} 分别表示前后两层森林的输出,若 $|O_{\text{pre}} - O_{\text{aft}}| \leq e$,则深度回归森林已生长到最大,不再具备区分特征的能力,停止生长并将最后一层森林的预测值作为整个模型的输出。为了增加模型的泛化能力,以及确保在模型生长的过程中不丢失信息,将前一层回归树的输出与原始数据线性组合后作为下一层森林的输入数据。

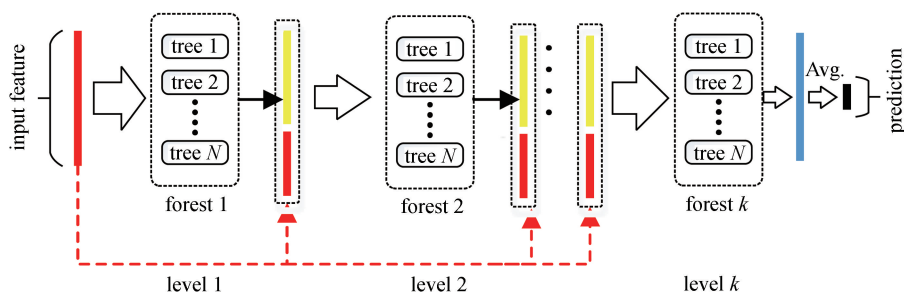


图2 深度回归森林结构

Fig. 2 Architecture of deep regression forest

4 模型整体框架

图3为本文模型的整体框架。假设输入一张原始大小的图像,首先将图像分割成 72×72 的小块,并使用对比度归一化处理。通过使用卷积池化操作,将每一个图像块处理成256个 8×8 大小的特征图,并通过2个全连接层得到一个特征值。由于每张图像切割成60个小块,因此最终每一张原始图像可以获得一个60维的特征向量,以此作为深度森林

的输入。深度森林中每一层采用500棵回归树进行训练,并将60维的图像特征向量扩展到500维,增加数据间的差异性,将经过森林扩展后的特征与原始特征线性组合,作为下一层的输入,直到两层间的验证误差小于给定阈值。

对于测试图像,同样使用切块的方式获得图像块,由卷积神经网络获得特征值后,由深度回归森林进行最后的质量预测,将最后一层森林的输出值取平均值作为测试图像最后的质量分数。




图3 本文模型整体框架

Fig. 3 Overall framework of proposed model

5 实验结果与分析

5.1 数据集

在德克萨斯大学奥斯汀分校建立的LIVE数据库^[18]和乌克兰国家航空航天大学建立的TID2008数据库^[19]这2个公开的图像质量评价数据库上验证模型性能。表1列举了2个数据库的具体信息,包括原始图像数、失真图像数、失真类型数,以及参与测试人数。LIVE数据库在29张原始图像上加入了5种常见失真类型:JPEG2000(JP2K)、JPEG、白噪声(WN)、模糊噪声(BLUR)和快速衰落(FF),获得了共779张失真图片;TID2008数据库中的失真类型则更加具体,总共有1700张失真图像。这2个数据库分别以平均主观得分差(DMOS)和平均主观得分(MOS)作为评价图像质量的参考分数,其中DMOS表示失真

图像与原始图像的分数差,范围在 $[0, 100]$,分数越低,图像质量越好;MOS表示图像的实际打分,范围在 $[0, 9]$,分数越高,图像质量越好。为了方便数据的后续处理,采用min-max标准化方法,将2个指标的值都归一化到 $[0, 1]$ 之间,转换公式如下:

$$X_{\text{norm}} = \frac{X_u - X_{\min}}{X_{\max} - X_{\min}}, \quad (12)$$

式中: X_{norm} 为归一化后的单一图像分数; X_u 为原始单一图像分数; X_{\max} 和 X_{\min} 分别为所有原始图像分数中的最大值和最小值。

选取斯皮尔曼等级相关系数(SROCC)和皮尔森相关系数(LCC)来验证模型性能,其中SROCC用于衡量模型预测的单调性,LCC用于评估模型预测的准确性,这2个指标越接近1,表明模型的性能越好。

表1 图像质量评价标准数据库

Table 1 Standard databases of image quality assessment

Image database	Number of reference images	Number of distorted images	Number of distortion types	Number of people tested
LIVE	29	779	5	161
TID2008	25	1700	17	838

5.2 LIVE 数据库实验结果

将数据库中所有失真图像按照图像内容不相同原则分成 80% 的训练样本和 20% 的测试样本两部分。首先使用训练集训练卷积神经网络模型并提取图像特征,然后使用深度回归森林预测图像质量。重复上述预测过程 1000 次,最后取 1000 次测试结果的均值作为最终的算法性能评价,这样可以有效降低测试过程受训练过程的影响。为了保证训练样本的充足性,采用文献[13]的方法将每块图像均采用随机定点的方式切成 60 张 72×72 大小的图像块,由于实验所用图像失真均匀,因此原图像的分数值可以当作是小图像块的

表2 LIVE 数据库上 SROCC 实验结果比较

Table 2 Comparison of SROCC experimental results on LIVE database

Model	JP2K	JPEG	WN	BLUR	FF	ALL
DIIVINE ^[6]	0.913	0.910	0.984	0.921	0.863	0.916
BLIINDS-II ^[20]	0.929	0.942	0.969	0.923	0.889	0.931
BRISQUE ^[7]	0.914	0.965	0.979	0.951	0.877	0.940
CORNIA ^[21]	0.943	0.955	0.976	0.969	0.906	0.942
CNN ^[11]	0.952	0.977	0.978	0.962	0.908	0.956
Proposed	0.967	0.974	0.983	0.971	0.938	0.972

表3 LIVE 数据库上 LCC 实验结果比较

Table 3 Comparison of LCC experimental results on LIVE database

Model	JP2K	JPEG	WN	BLUR	FF	ALL
DIIVINE ^[6]	0.922	0.921	0.988	0.923	0.888	0.917
BLIINDS-II ^[20]	0.935	0.968	0.980	0.938	0.896	0.930
BRISQUE ^[7]	0.922	0.973	0.985	0.951	0.903	0.942
CORNIA ^[21]	0.951	0.965	0.987	0.968	0.917	0.935
CNN ^[11]	0.953	0.981	0.984	0.953	0.933	0.953
Proposed	0.971	0.979	0.983	0.985	0.944	0.975

5.3 TID2008 数据库实验结果

由于本文模型是由训练得到的,为了验证其泛化性能,使用 2 个完全独立的数据库进行训练和测试。选择整个 LIVE 数据库共 779 张自然失真图片作为训练数据,由于 TID2008 数据库具有更多失真类型且含有人工合成图片,因此测试时只选用 JP2K、JPEG、BLUR、WN 等 4 种失真类型,且不包括人工合成图片,共 384 张,测试模型性能,共进行 1000 次训练测试,各算法指标结果如表4所示。从

分数。对原图像进行分割不仅可以大大增加训练数据量,避免过拟合,而且有助于预测局部区域图像质量。使用随机梯度下降(SGD)算法优化网络参数,初始学习率设置为 0.01,采用指数衰减法在多次迭代后将学习率降低,以达到加速网络收敛的目的。指数衰减法定义为

$$l_{\text{new}} = l_{\text{old}} \times d_{\text{rate}}^{\text{fror}} \left(\frac{g_{\text{step}}}{d_{\text{step}}} \right), \quad (13)$$

式中: l_{old} 与 l_{new} 分别表示更新前后的学习率; d_{rate} 表示衰减系数,设定为 0.85; g_{step} 与 d_{step} 分别表示全局步数与衰减步长,初始值为 0 和 25000。

表 2 和表 3 分别记录了本文模型与现今代表性的无参考图像质量评价方法 DIIVINE^[6]、BLINDS-II^[20]、BRISQUE^[7]、CORNIA^[21] 和 CNN^[11] 等在 LIVE 数据库上的实验结果(每种失真上表现最好的 3 种算法以加粗标识)。本文模型在 ALL 失真图像上优势明显,在单一的 JP2K、WN、BLUR 和 FF 失真上也有一定的优势,表明该模型具有更好的主观一致性。

表4 TID2008 数据库上 SROCC 与 PLCC 实验结果比较

Table 4 Comparison of SROCC and PLCC experimental results on TID2008 database

Model	SROCC	LCC
CORNIA ^[21]	0.890	0.880
BRISQUE ^[7]	0.882	0.892
CNN ^[11]	0.920	0.903
Proposed	0.935	0.929

表 4 可知,本文所提出的模型在泛化性能上具有良好的表现,测试结果优于传统基于人工提取特征学

习的算法和单一卷积神经网络学习的无参考图像质量评价方法。图4所示为所提模型预测值与MOS值的散点分布图,图中散点均匀分布在直线两侧,表明所提模型具有较好的主观一致性。




图4 TID2008数据库预测散点图

Fig. 4 Predicted scatter plot of TID2008 database

5.4 运算时间对比

由于客观图像质量评价多用于实时应用系统中,因此其运算速度是一个比较重要的问题。实验硬件选用戴尔笔记本电脑,搭载2.3 GHz CPU与GTX1050ti GPU。本文模型与CNN^[11]、BRISQUE^[7]、CORNIA^[21]等其他无参考图像质量评价模型的运算平均时间分别为0.561, 0.114, 0.725, 1.590 s。结果表明,本文模型在运算时间上优于传统基于手工提取特征的方法,更多卷积层数与更大图像块是本文模型与文献[11]模型运算时间相差较大的主要原因。综上所述,本文模型能在性能与计算时间上取得更好的结果。

6 结 论

提出了一种卷积神经网络与回归森林结合的无参考图像质量评价算法。首先通过对原始图像切块并进行局部亮度归一化预处理图像,然后使用CNN提取小块图像特征,并将所提特征使用深度回归森林进行质量预测。通过在LIVE数据库与TID2008数据库上的实验结果表明,本文方法具有较好的泛化性能与主观一致性。相比于以往端到端的CNN模型,本文算法在训练过程上分成了两步,在模型训练时间上比传统无参考方法耗时。因此,缩短训练耗时将是本文算法改进的重点。

参 考 文 献

[1] Wang Z, Bovik A C. Modern image quality assessment[J]. *Synthesis Lectures on Image, Video, and Multimedia Processing*, 2006, 2(1): 1-156.

[2] Wang Z M. Review of no-reference image quality assessment[J]. *Acta Automatica Sinica*, 2015, 41(6): 1062-1079.

王志明. 无参考图像质量评价综述[J]. *自动化学报*,

2015, 41(6): 1062-1079.

- [3] Zhao W Z, Qin S Y. Image quality assessment and some solving approaches to current issues[J]. *Laser & Optoelectronics Progress*, 2010, 47(4): 041002.
- 赵文哲, 秦世引. 图像质量评价的研究进展和若干问题的解决途径[J]. *激光与光电子学进展*, 2010, 47(4): 041002.
- [4] Zhang F, Zhang R Y, Li Z Z. Image quality assessment based on symmetry phase congruency[J]. *Laser & Optoelectronics Progress*, 2017, 54(10): 101003.
- 张帆, 张偲雅, 李珍珍. 基于对称相位一致性的图像质量评价方法[J]. *激光与光电子学进展*, 2017, 54(10): 101003.
- [5] Zhang Y, Jin W Q. Assessment method of fusion image quality in wavelet domain structural similarity[J]. *Chinese Journal of Lasers*, 2012, 39(s1): s109007.
- 张勇, 金伟其. 小波域结构相似度融合图像质量评价方法[J]. *中国激光*, 2012, 39(s1): s109007.
- [6] Moorthy A K, Bovik A C. Blind image quality assessment: from natural scene statistics to perceptual quality[J]. *IEEE Transactions on Image Processing*, 2011, 20(12): 3350-3364.
- [7] Mittal A, Moorthy A K, Bovik A C. No-reference image quality assessment in the spatial domain[J]. *IEEE Transactions on Image Processing*, 2012, 21(12): 4695-4708.
- [8] Saad M A, Bovik A C, Charrier C. A DCT statistics-based blind image quality index[J]. *IEEE Signal Processing Letters*, 2010, 17(6): 583-586.
- [9] Li C F, Bovik A C, Wu X J. Blind image quality assessment using a general regression neural network[J]. *IEEE Transactions on Neural Networks*, 2011, 22(5): 793-799.
- [10] Li C F, Zhang Y, Wu X J, *et al.* A multi-scale learning local phase and amplitude blind image quality assessment for multiply distorted images[J]. *IEEE Access*, 2018, 6: 64577-64586.
- [11] 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, 2014: 1733-1740.
- [12] Wu M Y, Chen L. Blind image quality assessment via convolutional neural network [C] // 2016 9th International Symposium on Computational Intelligence and Design (ISCID), December 10-11,

- 2016, Hangzhou, China. New York: IEEE, 2016: 221-224.
- [13] Wu L X, Sang Q B. No-reference multiply distorted images quality assessment based on convolutional neural network[J]. *Optical Technique*, 2018, 44(5): 555-561.
武利秀, 桑庆兵. 基于卷积神经网络的无参考混合失真图像质量评价[J]. *光学技术*, 2018, 44(5): 555-561.
- [14] Zhang Y, Wang W J, Kang X P. A regression SVM selection ensemble approach[J]. *Computer Science*, 2008, 35(4): 178-180.
张妤, 王文剑, 康向平. 一种回归 SVM 选择性集成方法[J]. *计算机科学*, 2008, 35(4): 178-180.
- [15] Zhou Z H, Feng J. Deep forest: towards an alternative to deep neural networks[EB/OL]. (2018-05-14) [2018-11-01]. <https://arxiv.org/abs/1702.08835v2>.
- [16] Zhou Z H. *Machine learning*[M]. Beijing: Tsinghua University Press, 2016: 171-178.
周志华. *机器学习*[M]. 北京: 清华大学出版社, 2016: 171-178.
- [17] Zhang C S, Cui L J, Yang G, *et al.* Comparative study for ensemble learning algorithms[J]. *Journal of Hebei University (Natural Science Edition)*, 2007, 27(5): 551-554.
张沧生, 崔丽娟, 杨刚, 等. 集成学习算法的比较研究[J]. *河北大学学报(自然科学版)*, 2007, 27(5): 551-554.
- [18] Sheikh H R, Wang Z, Cormack L, *et al.* LIVE image quality assessment database release 2 [OL]. [2018-11-01]. <http://live.ece.utexas.edu/research/quality>.
- [19] 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.
- [20] Saad M A, Bovik A C, Charrier C. Blind image quality assessment: a natural scene statistics approach in the DCT domain[J]. *IEEE Transactions on Image Processing*, 2012, 21(8): 3339-3352.
- [21] Ye P, Kumar J, Kang L, *et al.* Unsupervised feature learning framework for no-reference image quality assessment [C] // 2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE, 2012: 1098-1105.