

基于哈希算法及生成对抗网络的图像检索

彭晏飞, 武宏*, 訾玲玲

辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105

摘要 哈希方法是大规模图像检索中生成哈希码的有效方法。现有的哈希方法首先提取描述图像整体的特征, 然后生成哈希码, 但得到的哈希码并不精确。为了得到更精确的检索效果, 提出一种新的检索方法, 即采用卷积神经网络提取图像特征, 利用哈希算法与输入二进制噪声变量的生成对抗网络共同学习图像的二进制哈希码, 利用汉明距离对图像进行相似性比较, 最后完成对图像数据的有效检索。在标准图像数据集上进行实验, 结果证明, 该方法可以有效地进行图像检索, 相比现有的哈希方法, 该方法的检索性能也得到了提升。

关键词 图像处理; 图像检索; 卷积神经网络; 哈希算法; 生成对抗网络

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP55.101002

Image Retrieval Based on Hash Method and Generative Adversarial Networks

Peng Yanfei, Wu Hong*, Zi Lingling

School of Electronic and Information Engineering, Liaoning Technical University,
Huludao, Liaoning 125105, China

Abstract Hash method is an effective method for generating hash codes in large-scale image retrieval. The current hash method extracts the characteristics of the whole image first and then generates hash code, but the obtained hash code is not very precise to obtain more precise retrieval effect. Aiming at this problem, we propose a new method. First, we use a convolutional neural network to extract image features. Then, we adopt hash algorithm and generative adversarial network of input binary noise variable to learn image binary hash code, and carry out image similarity comparison by using hamming distance. Finally, we complete the effective retrieval of image data. Experiments on standard image data sets show that this method can effectively perform image retrieval, and the retrieval performance is improved than other methods.

Key words image processing; image retrieval; convolution neural network; hash method; generative adversarial network

OCIS codes 100.2960; 100.4996; 100.3008

1 引言

图像检索是图像处理的重要问题之一, 其目的是根据查询图像从数据集中找到与之相似的图像。之前的图像检索方法大多是基于提取图像纹理、颜色、形状特征来进行相似性匹配去完成图像检索, 随着人工智能时代的到来, 利用深度学习进行图像特征提取的方法得到了广泛应用^[1-4], 这种方法可以使

图像检索的结果更加准确。

现有的哈希方法通常可以分为无监督哈希方法、半监督哈希方法和监督哈希方法^[5-7]。无监督哈希方法的学习过程是不需要标签的; 半监督哈希方法考虑图像部分的相似性信息; 监督哈希方法利用预先定义的标签生成二进制哈希码^[8], 是现在最成功的方法。Strecha 等^[9]开发了一种监督学习, 提出学习哈希码, 近似于标签的相似度。通常来讲, 监督

收稿日期: 2018-02-23; 修回日期: 2018-03-23; 录用日期: 2018-04-27

基金项目: 国家自然科学基金(61702241)、辽宁省教育厅高等学校基本科研项目(LJ2017FBL004)、辽宁省教育厅科学研究一般项目(L2015225)、辽宁省博士科研启动基金(201601365)

* E-mail: 1028502590@qq.com

哈希方法优于无监督哈希方法,但监督哈希方法需要标签,而标签是稀缺和主观的。无监督的方法不能够充分利用现有的深度学习模型,不能产生更准确的结果,难以获得满意的性能。Goodfellow 等^[10]提出了生成对抗网络(GAN),该网络在计算机视觉和自然语言处理中得到了广泛应用。简言之,GAN是一种用于玩最小-最大(min-max)游戏的架构,其中,两个相互竞争的过程旨在最大化两者,但又相互冲突。GAN已在不同的应用环境中显示了有效性,并已开发了最初的GAN概念的各种变体^[11-12]。Radford 等^[13]提出了一种使用深度卷积生成对抗性网络(DCGAN)的无监督特征学习方法,该方法被证明优于其他无监督算法。基于此,本文提出一种结合哈希算法与GAN进行图像检索的无监督哈希方法。利用卷积神经网络(CNN)作为编码器^[14-16],提取图像特征,并将哈希层嵌入CNN中,进行初步二进制哈希码的生成,利用GAN与其前面工作在相互作用下生成更精确的哈希码,整个过程在无监

督的形式下进行,即不利用标签去生成哈希码,然后对得到的哈希码进行汉明距离计算,且对结果进行二次筛选和排查,得到最终的图像检索结果^[17]。实验结果表明,本文方法在查准率(P)和查全率(R),以及 P - R 曲线上的结果均优于对比的其他哈希方法。

2 本文方法

所提出的无监督的图像检索方法如图1所示。模型框架分为三个部分:第一部分为生成哈希码,目的是将生成的哈希码作为生成对抗网络的输入部分,将哈希函数嵌入卷积网络中并在 K 近邻算法(KNN)构成的近邻结构的辅助下生成哈希码;第二部分是哈希码的优化训练过程,将上述过程中生成的哈希码提供给GAN作为输入,利用GAN中生成器、判别器,以及损失函数进行训练,目的是使哈希码更准确化;第三部分利用汉明距离进行图像间相似性的计算,以达到图像检索的最终目的。

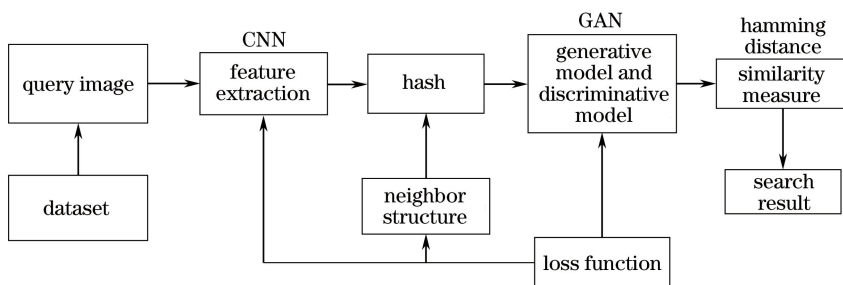


图1 检索任务框架示意图

Fig. 1 Frame diagram of retrieval task

2.1 无监督条件下生成哈希码

生成哈希码的过程,首先利用CNN提取图像特征,并通过哈希函数完成哈希码的生成,与此同时,利用KNN构造近邻结构指导哈希函数的学习过程。在监督哈希方法中,利用数据集的标签信息或相似性点信息作为监督信息,从而达到检索的目的,但标签是稀缺和主观的,所以本文选择在无监督条件下进行。构造近邻结构的最终目的是像监督方法一样用相似点作为信息,以达到仿监督哈希算法的效果。卷积网络模型采用经典的深度网络结构VGG-19模型,并将哈希层嵌入到卷积网络模型中。利用VGG模型提取FC7全连接层的图像特征,使图像特征向量在哈希函数的作用下生成连续的哈希码值。为避免出现梯度消失的问题,选择双正切激活函数来近似代替符号函数作为哈希层的最高层的激活函数,表示如下:

$$\tan h [\eta^{(i)}] = \frac{1 - \exp[-\epsilon \eta^{(i)}]}{1 + \exp[-\epsilon \eta^{(i)}]}, i = 1, 2, \dots, q, \quad (1)$$

式中 $\eta^{(i)} = f_i[x^{(i)}]$, 参数 ϵ 用于控制平滑度。 $\mathbf{R} = [\eta^{(1)}, \eta^{(2)}, \dots, \eta^{(q)}]^T$ 为输出的连续的哈希编码值,其将利用哈希函数中的阈值化层将 q 维连续的哈希编码值进量化为 -1 和 1 , 最后输出的便是连续哈希编码值经过量化处理后形成的二进制哈希码 b 。辅助哈希函数学习过程基于KNN构造一个近邻矩阵 \mathbf{M} 。在卷积网络过程中得到图像特征向量集合 $X = \{x_i\}_{i=1}^N$, 其原理是表明任意两个图像 i 和 j 在特征 x_i 和 x_j 的相似点 ($\mathbf{M}_{ij} = 1$) 和非相似点 ($\mathbf{M}_{ij} = -1$)。利用图像特征向量的余弦相似来比较图像,对于每个图像,选择 K_1 个具有高余弦相似的图像作为它的邻域,目的是构造一个最初的相似矩阵 \mathbf{M}_1 :

$$(\mathbf{M}_1)_{ij} = \begin{cases} 1, & \text{if } x_j \text{ is } K_1 \text{ of } x_i \\ -1, & \text{otherwise} \end{cases}. \quad (2)$$

然后,基于相似矩阵 \mathbf{M}_1 扩展邻域结构,计算两个图片的相似性,继续构造一个 K_2 邻域的排序列表,生成第二个相似矩阵 \mathbf{M}_2 :

$$(\mathbf{M}_2)_{ij} = \begin{cases} 1, & \text{if } x_j \text{ is } K_2 \text{ of } x_i \\ -1, & \text{otherwise} \end{cases}. \quad (3)$$

最后将两个矩阵结合起来,得到最终的相似矩阵 \mathbf{M} :

$$\mathbf{M}_{ij} = \begin{cases} 1, & \text{if } (\mathbf{M}_1)_{ij} = 1 \text{ or } x_j \text{ is a } K_1 \text{ NN of } x_i \text{ s } K_2 \text{ NN} \\ -1, & \text{otherwise} \end{cases}. \quad (4)$$

2.2 利用生成对抗网络优化训练哈希码

GAN 的结构就是生成器和判别器的结合,模型通过框架中两个模块——生成模块和判别模块的互相博弈学习过程从而产生较好的输出。本文 GAN 的计算流程与结构如图 2 所示。




图 2 GAN 的运算流程与结构

Fig. 2 Computation procedure and structure of GAN

如图 2 所示,生成器是将上述过程中生成的哈希码 b 作为输入,进入图像的生成器,同时输入二进制噪声变量,利用生成模块对所生成的二进制哈希码进行训练,同时,将生成的新的二进制哈希码与原二进制哈希码进行比较,即利用判别模块判别真实数据与新生成的数据。在生成模块和判别模块的相互“博弈”过程中,要保证两个对抗网络的平衡和同步,不断进行 GAN 网络的训练,以达到生成更精确二进制码的目的。同时,也可以利用此时的哈希码生成和原始图像相似的图像。

为了增强 GAN 网络训练的效果,在有损失函数的前提下,另选择合适的优化器来优化网络训练进程。本文选择的是结合 Nesterov 动量的 RMSProp 算法对 GAN 训练过程进行优化,RMSProp 算法可以改变学习率,Nesterov 动量可以改变梯度,两者结合可以使参数空间更为平缓,历史梯度平方和较小,令学习下降的幅度变小,从而达到自动改变学习速率的目的,因此更稳定,也更适合处理非平稳目标。为了减少训练误差,可以多次遍历数据集,每次遍历时随机抽取 m 个样本(保证样本不会重复),利用选取的样本来计算梯度 g ,以此来更新参数 χ (χ 为 GAN 训练中生成模块的参数)。设置衰减系数为 β ($\beta=0.0005$),动量系数为 α ($\alpha=0.9$),累计梯度为 r (初始化为 0),按照以下公式进行参数更新:

$$r \leftarrow \beta r + (1 - \beta)g \odot g, \quad (5)$$

$$v \leftarrow \alpha v - \frac{\delta}{\sqrt{r}} \odot g, \quad (6)$$

$$\chi \leftarrow \chi + v, \quad (7)$$

式中 δ 为全局学习率, v 为初始参数。

该算法可以根据每次迭代过程的不同情况对学习率进行自动调整,使得参数也更加平稳。

2.3 损失函数

损失函数会影响整个算法的整体优化,但是可以通过不断优化生成图像,使其越来越接近训练图像以去除监督学习的需求,同时,采取相适应的哈希算法以非监督的方式得到更精准的二进制哈希码也是本文的目的。因此,利用损失函数的评估解决方案与感知相关性的特性,将相邻结构损失、内容损失,以及相对原始 GAN 改良之后的对抗性损失进行加权求和得到总体损失,即:

$$L = L_N + \lambda_1 L_C + \lambda_2 L_A. \quad (8)$$

L_N 为邻域结构损失,是数据相似结构中的损失模型,通过应用该图像的二进制哈希码($B = \{b_i\}_{i=1}^N$)和相似矩阵作为图像间相互关系的参考,通过相似矩阵 \mathbf{M} 与哈希码 b 的相互运算,利用相似矩阵将图像进行分类,使相似图像分到一类,并使相似图像的哈希码尽可能相近。定义邻域结构损失为

$$L_N = \frac{1}{2} \sum_{\mathbf{M}_{ij} \in \mathbf{M}} \left(\frac{1}{L} b_i^T b_j - \mathbf{M}_{ij} \right)^2. \quad (9)$$

L_C 为内容损失,是重建图像质量损失的模型,最广泛使用的像素化均方差(MSE)损失计算为

$$L_{\text{MSE}} = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H (I_{ij} - I_{ij}^R)^2, \quad (10)$$

式中 W, H 表示特征维度。由于 MSE 优化问题通常缺乏高频内容,其纹理也过于平滑,因此将像素化 MSE 损失和卷积网络中的损失函数相结合效果更加。用 θ 指出通过最后卷积层得到的特征并定义 VGG 损失,使用欧几里得距离作为重构图像 I^R 和原始图像 I 的特征表示:

$$L_{\text{per}} = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H [\theta(I_{ij}) - \theta(I_{ij}^R)]^2. \quad (11)$$

上述过程中得到的哈希码为离散值,需要加入将连续值二值化为离散值时带来的误差。在目标损失函数中加入哈希函数输出的连续值编码和阈值化层输出的哈希码之间的量化误差损失,表示为

$$L_H = \frac{1}{2} \| \mathbf{h} - \mathbf{R} \|_2^2, \quad (12)$$

式中 $\mathbf{h} = \{g[\mathbf{R}^{(1)}], g[\mathbf{R}^{(2)}], \dots, g[\mathbf{R}^{(q)}]\}^T$ 为阈值化层输出的哈希码, \mathbf{R} 为激活层输出的连续值编码。该损失函数的目标是降低阈值化带来的误差。基于以上描述,内容损失函数为

$$L_C = L_{\text{MSE}} + L_{\text{per}} + L_H. \quad (13)$$

L_A 为对抗性损失模型,在原始图像和重构图像结构中利用对抗损失减少图像的误分类。GAN 只有在生成器和判别器的相互作用和相互竞争下达到平衡状态时才会有较好的训练效果。设定真实样本分布为 P_z ,生成样本分布为 P_s ,若 P_z 和 P_s 之间没有关联或者重叠部分可以忽略不计,判别器训练也将达到最优,但此时生成器的梯度也消失了,便不能得到理想的训练效果;若判别器训练得不够好,则生成器的梯度也会不稳定,同样得不到理想的训练效果。以上两方面原因导致 GAN 训练过程结果不稳定。因其在无监督的条件下进行,结合以上分析可知,对抗损失应选择可以提供有意义梯度且平滑的 Wassertein 距离进行计算,并且利于 GAN 的训练。Wassertein 距离定义如下:

$$W(P_z, P_s) = \inf_{\gamma \in \Pi(P_z, P_s)} E_{(x,y) \sim \gamma} [\|x - y\|], \quad (14)$$

式中 $\Pi(P_z, P_s)$ 是所有可能的联合分布 γ 的集合,采用一个真实样本 x 和一个生成样本 y 计算样本对距离的期望,最后求期望的下界,即为所求的 Wassertein 距离。但由于期望的下界不易计算,所以,将(14)式最终利用相关定理转换为如下形式,即用一组参数 φ 定义判别器中的一系列连续函数 f_φ :

$$W(P_z, P_s) \cdot \lambda \approx \max_{\varphi: \|f_\varphi\|_L \leq \lambda} E_{x \sim P_z} [f_\varphi(x)] - E_{x \sim P_s} [f_\varphi(x)], \quad (15)$$

式中 λ 为函数 f_φ 的 Lipschitz 连续的常数($\lambda \geq 0$)。当 Wassertein 距离最小时,对抗网络的训练效果最好,最后可得出生成器和判别器的损失分别为 $-E_{x \sim P_z} [f_\varphi(x)]$ 和 $E_{x \sim P_z} [f_\varphi(x)] - E_{x \sim P_s} [f_\varphi(x)]$ 。

3 实验与分析

本文实验平台为 Intel(R) Core(TM) i5, CPU @ 3.2 GHz 处理器, 8 GB 运行内存, NVIDIA GeForce GTX1050Ti GPU, Tensorflow 平台。本文在标准图像数据集 CIFAR-10 上进行实验,来验证该检索方法的有效性。

3.1 对比方法

为了验证本文检索方法的有效性,在实验中利用以下主流哈希算法与本文算法进行比较,分别为迭代量化哈希(ITQ)、光谱哈希(SH)、局部敏感哈希(LSH)、球哈希(SpH)、主成分分析哈希(PCAH),以及深度监督哈希(DSH)。为了保证算法对比的公平性,所有的算法均未对图片做任何事先的处理操作。

3.2 数据集及评价指标

数据集: CIFAR-10 数据集包含有 60000 张大小为 $32 \text{ pixel} \times 32 \text{ pixel}$ 的彩色图片,图片分为 10 个类别,包含猫、汽车、飞机等分类,每个类别有 6000 张图片。

评价指标: 本文采用 3 个评价指标来评价算法的性能,分别为 P, R 和 $P-R$ 曲线。 P 指的是查准率,即已被检索样本的准确率; R 指的是查全率,即正确的样本被检索到的概率。一般情况下,人们希望查准率和查全率都是越高越好,实际上,这两个指标是负相关关系。但是, $P-R$ 曲线的高低和算法的准确率呈正相关关系,所以也可以使用 $P-R$ 曲线来评估算法的性能。

3.3 实验结果分析

3.3.1 训练及测试时间

本文算法在 CIFAR-10 数据集上进行训练和测试,由于 GAN 的训练难度较大,因此,会花费较多的时间训练(5.5 h)和测试(5 ms),但是所生成的哈希码相对精准。

3.3.2 查准率对比结果分析

由图 3 可以看出,在不同编码位数下,本文检索方法的查准率均优于其他对比算法,即利用 GAN 博弈性质进行实验最后得到的二进制哈希码更为准确,因而检索效果也会更好。当编码位数较短为 16 位时,如图 3(a)所示,与 LSH、DSH 和 SpH 算法相

比,本文算法具有明显的优势;当编码的位数增加到32位时,如图3(b)所示,检索的精度也均有小幅度的增加,跟LSH、PCAH和SH算法相比,本文算法的检索精度相对较高;当编码位数为64位时,如图3(c)所示,PCAH算法的精度增长较快,但本文算法此时较

PCAH、SH、LSH算法仍然存在检索精度的优势。随着编码位数增加,对比的哈希算法检索精度逐渐增加,但幅度不是很大,而本文算法随着编码位数的增加,检索精度一直呈现上升趋势,故以此评判,本文算法在查准率方面优于其他对比哈希算法。




图3 (a) 16位、(b) 32位、(c) 64位编码下不同算法的查准率对比

Fig. 3 Comparison of precision of different algorithms under (a) 16 b, (b) 32 b, (c) 64 b encoding

3.3.3 查全率对比结果分析

从图4可以看出,随着检索返回图像数增加,所有相关图像被检索到的可能性也随之增加,因而查全率也会随之升高。当编码位数为16位时,如图4(a)所示,本文算法的查全率明显优于其他对比算

法;当位数增加到32位时,如图4(b)所示,本文算法相对于LSH、PCAH、SH有明显的优势;当编码位数为64位时,如图4(c)所示,PCAH算法的上升趋势明显,但本文算法仍略优于该算法。整体看来,本文算法在查全率上也是优于其他对比算法的。




图4 (a) 16位、(b) 32位、(c) 64位编码下不同算法的查全率对比

Fig. 4 Comparison of recall of different algorithms under (a) 16 b, (b) 32 b, (c) 64 b encoding

3.3.4 P-R 曲线分析

P-R曲线是指所有测试图像在汉明空间从大到小进行排序后,由查准率和查全率围成的曲线图。由图5可以看出,当编码位数由16位增加到64位时,PCAH算法的P-R曲线呈略下降趋势,而ITQ

算法随着编码位数的增加,上升趋势不是很大,但相对稳定。本文算法随着编码位数增加虽然没有明显的上升趋势,但处于稳定状态,且与其他对比算法相比,本文算法的P-R曲线仍存在优势。综言,本文算法与其他算法相比仍存在优势。




图5 (a) 16位、(b) 32位、(c) 64位编码下P-R曲线对比

Fig. 5 Comparison of P-R curve under (a) 16 b, (b) 32 b, (c) 64 b encoding

4 结 论

提出一种基于哈希算法和生成对抗网络进行图像检索的方法。在所提出的框架中,利用卷积神经网络提取图像特征,并将哈希层嵌入到卷积神经网络结构模型中,基于 KNN 分类算法构造近邻结构指导哈希学习过程,然后利用生成对抗网络对上述过程得到的二进制哈希码进行优化,限制输入的噪声变量为二进制形式,考虑提取特征、哈希码生成过程和生成对抗网络过程中的误差,最终得到更精确的二进制码。与对比的监督和非监督哈希算法相比较,本文方法的检索精度得到了提升。

参 考 文 献

- [1] Cao Z, Long M, Wang J, *et al.* HashNet: deep learning to Hash by continuation [C] // IEEE International Conference on Computer Vision, 2017: 5609-5618.
- [2] Liu B, Zhang H. Image retrieval algorithm based on convolutional neural network and manifold ranking [J]. Journal of Computer Applications, 2016, 36(2): 531-534, 540.
刘兵, 张鸿. 基于卷积神经网络和流形排序的图像检索算法[J]. 计算机应用, 2016, 36(2): 531-534, 540.
- [3] Liu Y, Pan Y, Xia R K, *et al.* FP-CNNH: a fast image hashing algorithm based on deep convolutional neural network[J]. Computer Science, 2016, 43(9): 39-46, 51.
刘治, 潘炎, 夏榕楷, 等. FP-CNNH: 一种基于深度卷积神经网络的快速图像哈希算法[J]. 计算机科学, 2016, 43(9): 39-46, 51.
- [4] Peng T Q, Li F. Image retrieval based on deep convolutional neural networks and binary hashing learning[J]. Journal of Electronics & Information Technology, 2016, 38(8): 2068-2075.
彭天强, 栗芳. 基于深度卷积神经网络和二进制哈希学习的图像检索方法[J]. 电子与信息学报, 2016, 38(8): 2068-2075.
- [5] Li W J, Zhou Z H. Learning to hash for big data: current status and future trends[J]. Chinese Science Bulletin, 2015, 60(Z1): 485-490.
李武军, 周志华. 大数据哈希学习: 现状与趋势[J]. 科学通报, 2015, 60(Z1): 485-490.
- [6] Kan M N, Xu D, Shan S G, *et al.* Semisupervised hashing via kernel hyperplane learning for scalable image search[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2014, 24(4): 704-713.
- [7] Wang Y C, Guo J B, Zhou L Y. Image hash algorithm based on data dimension reduction and symmetric binary pattern [J]. Laser & Optoelectronics Progress, 2017, 54(2): 021004.
王彦超, 郭静博, 周丽宴. 基于数据降维与对称二值模式的图像 Hash 算法[J]. 激光与光电子学进展, 2017, 54(2): 021004.
- [8] Norouzi M, Fleet D J. Minimal loss hashing for compact binary codes[C] // Proceedings of the 28th International Conference on Machine Learning. 2011: 353-360.
- [9] Strecha C, Bronstein A M, Bronstein M M, *et al.* LDAHash: improved matching with smaller descriptors [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(1): 66-78.
- [10] Goodfellow I J, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets[C] // Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014: 2672-2680.
- [11] Chen X, Duan Y, Houthoofd R, *et al.* Infogan: interpretable representation learning by information maximizing generative adversarial nets [C] // Advances in Neural Information Processing Systems, 2016: 2172-2180.
- [12] Larsen A B L, Sønderby S K, Larochelle H, *et al.* Autoencoding beyond pixels using a learned similarity metric [C] // International Conference on Machine Learning, 2016: 1558-1566.
- [13] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. arXiv, 2015: 1511. 06434.
- [14] Oquab M, Bottou L, Laptev I, *et al.* Learning and transferring mid-level image representations using convolutional neural networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1717-1724.
- [15] Hou C C, He Y Q, Jiang X H, *et al.* Deep convolutional neural network based on two-stream convolutional unit [J]. Laser & Optoelectronics Progress, 2018, 55(2): 021005.
侯聪聪, 何宇清, 姜晓恒, 等. 基于二分支卷积单元的深度学习神经网络[J]. 激光与光电子学进展, 2018, 55(2): 021005.
- [16] Li S M, Lei G Q, Fan R. Depth map super-

resolution reconstruction based on convolutional neural networks [J]. *Acta Optica Sinica*, 2017, 37 (12): 1210002.

李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图超分辨率重建 [J]. *光学学报*, 2017, 37 (12):

1210002.

[17] Zhu H, Long M, Wang J, *et al.* Deep Hashing network for efficient similarity retrieval [C] // Thirtieth AAAI Conference on Artificial Intelligence, 2016: 2415-2421.