

# 一种基于卷积神经网络的立体匹配算法设计<sup>\*</sup>

鲁志敏,袁 勋,陈 松

(中国科学技术大学 信息科学技术学院,安徽 合肥 230026)

**摘要:**为了解决传统立体匹配算法对立体图像在低纹理以及遮挡区域匹配效果较差的问题,设计了一种端到端的基于卷积神经网络(Convolutional Neural Network,CNN)的立体匹配算法。该算法采取了残差卷积神经网络对图像特征进行提取,之后利用空洞空间金字塔池化(Atrous Spatial Pyramid Pooling,ASPP)模块来获取图像的上下文信息,并结合多尺度的三维卷积神经网络对代价空间进行规整,最终实现了高精度的立体匹配算法。所获取的视差图在 KITTI2015 测试平台上的误匹配率为 2.42%,与几何上下文(Geometry and Context,GC)网络相比较,视差图的精度提高了 0.45%,且运行时间缩短了一半。

**关键词:**卷积神经网络;立体匹配;空洞空间金字塔池化;误匹配率

**中图分类号:**TN47

**文献标识码:**A

**DOI:** 10.19358/j.issn.2096-5133.2020.05.001

**引用格式:**鲁志敏,袁勋,陈松.一种基于卷积神经网络的立体匹配算法设计[J].信息技术与网络安全,2020,39(5):1-5,21.

## A stereo matching algorithm based on convolutional neural network

Lu Zhimin, Yuan Xun, Chen Song

(College of Information Science and Technology, University of Science and Technology of China, Hefei 230026, China)

**Abstract:**In order to solve the problem of the poor matching effect of stereo image in low texture and occlusion area in traditional stereo matching algorithm, this paper designed an end-to-end stereo matching algorithm based on convolutional neural network (CNN). The algorithm adopts residual convolutional neural network to extract the image features, and then uses the atrous spatial pyramid pooling (ASPP) module to obtain the context information of the image, and combines the multi-scale three-dimensional convolutional neural network to regularize the cost volume, and finally realizes the high-precision stereo matching algorithm. The mismatch rate of the obtained disparity map on the KITTI2015 testing platform was 2.42%. Compared with the Geometry and Context (GC) network, the accuracy of the disparity map was improved by 0.45%, as well as the running time was reduced by half.

**Key words:** convolutional neural network; stereo matching; atrous spatial pyramid pooling; mismatch rate

### 0 引言

立体视觉作为计算机视觉最为热门的研究领域,广泛应用于车辆的自动驾驶、机器人导航、三维重建、物体检测和识别等方面。立体匹配作为立体视觉系统中的核心技术,其匹配的精确度决定着整个系统的性能。由于拍摄的立体图像大多存在噪声干扰、重复纹理、低纹理和遮挡区域等问题,并且受到光照条件的影响,如何高效快速地获取精准的视差图仍存在着诸多挑战。

立体匹配算法的典型流程包含匹配代价计算、

代价聚合、视差计算和视差优化四个步骤<sup>[1]</sup>,其又分为全局算法和局部算法。局部算法通常使用固定大小的窗口或可变的窗口来计算初始代价,例如 Census 算法等,实现都比较简便,但是在视差突变区域存在诸多弊端,对低纹理和遮挡区域匹配效果差。全局匹配算法通过建立全局能量函数,利用最小化全局能量函数来获取最优的视差值<sup>[2]</sup>。常用的全局匹配算法包含动态规划、图割法、置信传播法、遗传算法等。全局匹配算法随着计算复杂度的提升,匹配效果较局部算法有所提升,但数据依赖性大导致运行速度慢,需要花费很长的时间进行计算。

<sup>\*</sup> 基金项目:国家自然科学基金资助项目(61874102)

为了解决传统立体匹配算法在低纹理、遮挡区域的匹配效果差的问题,本文研究了一种端到端的基于卷积神经网络的立体匹配算法,并利用了空洞空间金字塔池化(ASPP)<sup>[3]</sup>网络获取图像的上下文信息和多尺度的三维卷积网络来扩大图像的感受野。最终获得的视差图的精度远高于传统匹配算法,对图像的边缘、遮挡区域的匹配效果都非常优异。

## 1 研究背景

近年来,随着计算能力的大幅提升,深度学习成为计算机视觉领域发展最为迅速的一种主流算法,在目标识别、物体跟踪、检测等方面大幅优于传统的图像算法。卷积神经网络(CNN)作为深度学习的热门研究方向,在计算机视觉领域取得了很多突破性成果。CNN的一个重要方面就是获取输入向更深层传播时的抽象特征。卷积操作过程如式(1)所示:

$$Z(i, j) = \sum_m \sum_n x(i + m, j + n) w(m, n) + b \quad (1)$$

其中, $Z$ 代表输出, $x$ 代表输入, $w$ 代表一个卷积核, $b$ 代表偏置项。卷积操作完成之后,对输出的结果通常会进行非线性激活,再作为下一层的输入。常用的非线性激活函数有修正线性单元(Rectified Linear Unit, ReLU)。卷积神经网络通过层层传播,并结合反向传播算法,可以提取出图像的抽象特征。

立体匹配的目标是计算出参考图像中的每个像素的视差值 $d$ 。假设给定一对经过校正的立体图像,左图像中的像素点为 $p(x, y)$ ,在右图像上的对应点为 $p'(x-d, y)$ ,则该像素的深度可以由 $fB/d$ 计算而来,其中 $f$ 为相机的焦距, $B$ 为左右相机光心之间的距离。目前,基于深度学习的立体匹配方法主要有三种,其中包含匹配代价学习、正则学习、端到端视差学习。ZBONTAR J 和 LECUN Y<sup>[4]</sup>于2015年首次将卷积神经网络(CNN)应用于立体匹配,该网络设计了一个深层的 Siamese 网络去计算匹配代价,在 KITTI2015<sup>[5]</sup>测试平台上的误匹配率为3.89%,引起了广泛关注。LUO W<sup>[6]</sup>等人提出了一个更快的 Siamese 网络,其中匹配代价的计算被视为多标签的分类问题。SGM-Net<sup>[7]</sup>学习预测半全局匹配(Semi-Global Matching, SGM)的惩罚项来代替人工调整规则化的惩罚项。近期,MAYER N<sup>[8]</sup>等人提出一个端到端的

网络来估算视差(DispNet)和光流(FlowNet),并提供了一个大型合成数据集(Scene Flow)用于网络训练。PANG J H<sup>[9]</sup>等人拓展了 DispNet 并引入了一种两级网络,称为级联残差学习(Cascade Residual Learning, CRL)。第一级和第二级网络分别计算视差图和多尺度的残差,然后两级网络的输出相加构成最终的视差图。KENDALL A<sup>[10]</sup>等人介绍了 GC-Net 网络,使用了3D卷积神经网络来调整匹配代价空间。上述的端到端方法都利用多尺度特征去估算视差图。CHANG J R<sup>[11]</sup>等人提出了一个全新的金字塔立体匹配(Pyramid Stereo Matching, PSM)网络,利用了空间金字塔池化(Spatial Pyramid Pooling, SPP)来获取多尺度的特征,并结合三个沙漏堆叠网络获得了更好的匹配效果。

## 2 ASPP-Net 模型架构设计

与传统的求视差图的步骤不同,本文利用深度学习的方式来学习从输入图像到视差图之间的端到端的映射。这种方式可以减少很多工程设计的复杂性,避免了视差优化等步骤。图1展示了 ASPP-Net 模型的体系架构。左右图像分别输入到两个权重共享的残差卷积神经网络<sup>[12]</sup>中用来提取特征,ASPP 模块用来获取图像的上下文信息。然后将左右图像特征连接形成4维的代价空间,之后通过多尺度的3D CNN 网络进行代价规整并最终通过视差回归得到精确的视差图。

### 2.1 特征提取网络

首先,本文学习了一种用于表示立体匹配代价的深度表示。采用特征图表示来取代使用原始像素强度计算而来的立体匹配代价。这样做的动机是比较一个描述符,该描述符对光学歧义更为鲁棒,而且可以结合局部上下文信息。在本文的模型中,使用了残差卷积网络来学习深度表示。因为残差网络不会随着网络层数的增多而出现梯度消失的现象。每个卷积层之后是批处理归一化层(Batch Normalization, BN)和非线性激活函数层(采取的是 ReLU 函数)。为了减少计算需求,该网络首先应用三个 $3 \times 3$ 的卷积滤波器对输入进行降采样处理。PSM-Net<sup>[11]</sup>设计的残差卷积网络深达28层。但是,文献[10]中仅采取了11层残差卷积网络也取得了高精度的视差图。因此,可推测 PSM-Net 中可能存在大量冗余参数。基于此,本文仅使用了15层残差




图1 所提出的 ASPP-Net 的体系架构

卷积网络。其中每个残差卷积模块由两个串联的卷积滤波器短接组成。为了减少网络的参数,卷积核的大小均为  $3 \times 3$ 。左右图像通过网络参数共享,来更有效地学习相对应的特征,最后提取出各自对应的特征图。

## 2.2 ASPP 模块组成

在 PSM-Net 中,使用空间金字塔池化 (SPP) 模块从多个尺度进行特征提取。受此启发,本文所提出的空洞空间金字塔池化 (ASPP) 模块使用空洞卷积来提取稠密特征图并捕获图像中长范围的上下文信息。具体来说,为了编码多尺度信息,该网络提出的级联模块逐渐使空洞率加倍,而带图像级特征增强的空间金字塔汇聚模块则使用多个采样速率来获取特征。在网络解码上对于不同尺度用不同大小的空洞率去抓取多尺度信息,每个尺度作为一个独立的分支,最后把它们合并起来再接一个卷积层输出最终的特征图。如图 1 所示,ASPP 模块包含空洞率分别为 6、12、18 的空洞卷积,然后结合全局平均池化层以及残差网络提取出的特征,合并在一起之后通过两个卷积层获取最终的特征图。实验结果表明,ASPP 模块可以有效避免在编码过程中冗余信息的获取,并有效提升视差图的精度。

## 2.3 代价空间

将左图像与右图像提取出的特征图经过相应的平移处理之后连接起来,并且打包到 4 维代价空

间中。这种方式可以保留根据立体视觉几何学知识的方式来约束模型。对于每个立体图像,代价空间的维度为  $1/4W \times 1/4H \times C \times 1/4D$ ,其中  $W$  和  $H$  分别代表立体图像的宽和高, $C$  代表融合后特征图的通道数, $D$  表示视差的最大范围。这种操作保留了特征图的维度,与采取点积操作来抽取特征图的维度方法不同,这使模型可以通过特征图来学习上下文信息。研究发现,与级联特征或使用距离度量相比,形成具有级联特征的代价空间可以显著提高性能。

## 2.4 3D 卷积网络设计

给定视差代价空间后,现在需要学习一个正则化函数,该函数可以考虑代价空间中的上下文关系从而优化视差估计。即使使用深层特征表示,一元之间的匹配代价也无法做到完美。例如,在像素强度均匀的区域(例如天空)中,基于固定的局部上下文的任何特征的代价曲线都将是平坦的。研究发现,像这样的区域会导致整个视差维度上的多模式匹配代价曲线,需要学习正则化函数并提高这一数量。因此,采取三维卷积运算来过滤和完善此表示。

3D 卷积能够从高度、宽度和视差维度学习特征表示。3D 卷积的困难在于额外的维度,在推理和训练阶段都带来了计算时间的负担。因此,代价空间在高度、宽度以及视差维度上分别缩减至原来的  $1/4$ ,从而减少计算量。针对密集预测任务的深度

编译码任务,本文通过在编码器中对特征图进行降采样,然后在解码器中进行上采样来减少参数。在编码上首先进行两次降采样处理,然后使用两个 3D 转置卷积网络对编码器中的输出进行上采样。利用多尺度的特征可以充分利用上下文信息,并且极大地减少网络规模,从而减轻计算负担。最后通过双线性插值算法进行上采样,得到维度为  $H \times W \times D$  的输出结果。

2.5 视差回归

通常,立体匹配算法从一元特征图中形成代价空间,该代价空间可以在视差维度上执行求最小值操作来估计视差。但是在训练过程中往往很难收敛。本文借鉴了文献[10]的操作。首先,使用 softmax 操作  $\sigma(\cdot)$  对最终融合的成本量  $c_d$  进行归一化,以输出每个视差  $d$  对应的概率;然后,预测的视差  $\hat{d}$  计算为每个视差  $d$  乘上其对应概率的总和,如式(2)所示:

$$\hat{d} = \sum_{d=0}^{D_{\max}} d \times \sigma(-c_d) \tag{2}$$

这个操作是完全可微的,可以进行训练和回归视差估计。根据文献[10]中论述,上述视差回归比基于分类的立体匹配方法更稳健。

2.6 损失函数

平滑的  $L1$  损失函数常用于目标检测的边界框回归问题中。与  $L2$  损失函数相比,平滑的  $L1$  损失函数鲁棒性更好,并且对异常值的敏感性较低。由于存在视差回归,因此平滑的  $L1$  损失函数可用于本文的模型训练,其公式如下所示:

$$L(d, \hat{d}) = \frac{1}{N} \sum_{i=1}^N \text{smooth}_{L_1}(d_i - \hat{d}_i) \tag{3}$$

其中,

$$\text{smooth}_{L_1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases} \tag{4}$$

式中,  $N$  代表被标记的像素个数,  $d$  代表地面真实视差,  $\hat{d}$  代表通过神经网络预测得出的视差值。

3 实验结果及比较

本文在 Scene Flow、KITTI2015 两个图像数据集上评估了所提出的方法。Scene Flow 是一个合成的数据集,其中包含 35 454 个训练图像和 4 370 个测试图像。这个场景提供了精确稠密的真实视差图信息。KITTI2015 是汽车驾驶时拍摄街景的真实路

况数据集,包含 200 幅带有地面真实视差的训练图像对,以及 200 幅没有地面真实视差的测试图像对。图像大小为 ( $H = 375, W = 1\ 242$ )。将整个训练数据分为训练集 (80%) 和验证集 (20%)。

ASPP-Net 的体系结构是使用 PyTorch 平台实现的。所有模型均端到端地进行训练,其中采取了 Adam 优化器,参数设置为  $\beta_1 = 0.9, \beta_2 = 0.999$ 。在 4 台 1080Ti GPU 服务器集群上进行了训练。整个数据集在训练过程中进行了数据归一化、裁剪等预处理。其中图片被随机裁剪成  $H = 256, W = 512$ 。最大视差  $D$  设置为 192。首先使用 Scene Flow 数据集从零开始训练模型,学习率为 0.001 且持续训练 10 轮。训练后的模型可直接用于测试。测试结果如表 1 所示。

表 1 不同网络在 Scene Flow 平台终点误差的比较

| 网络模型 | PSM-Net <sup>[11]</sup> | GC-Net <sup>[10]</sup> | CRL <sup>[9]</sup> | ASPP-Net |
|------|-------------------------|------------------------|--------------------|----------|
| EPE  | 1.09                    | 2.51                   | 1.32               | 1.05     |

从表 1 可以看出,本文提出的网络模型在 Scene Flow 平台下的终点误差 (End-Point-Error, EPE) 为 1.05,比 PSM-Net 低 0.04,远低于 GC-Net 的终点误差。

对于 KITTI2015 数据集,则采取了迁移学习的方法,将 Scene Flow 训练的模型在 KITTI2015 训练集上进行 500 个周期的微调,得到新的网络模型。学习率在前 200 个周期设置为 0.001,剩下的 300 个周期设置为 0.000 1,防止出现过拟合。将训练好的模型最终用于测试集,得到测试结果,如表 2 所示。

表 2 不同网络在 KITTI2015 平台误匹配率的比较

| 网络模型                    | All-all/% | Noc-all/% | Runtime/s |
|-------------------------|-----------|-----------|-----------|
| PSM-Net <sup>[11]</sup> | 2.32      | 2.14      | 0.41      |
| GC-Net <sup>[10]</sup>  | 2.87      | 2.61      | 0.90      |
| CRL <sup>[9]</sup>      | 2.67      | 2.45      | 0.47      |
| MC-CNN <sup>[4]</sup>   | 3.89      | 3.33      | 67        |
| ASPP-Net                | 2.42      | 2.24      | 0.45      |

表 2 中,All-all 代表全像素级别下的平均误匹配率,误匹配率表示预测视差与真实视差超过 3 个像素的错误匹配点的比例;Noc-all 代表去除掉遮挡区域下的其余所有像素的平均误匹配率。本文提出的算法的 All-all 为 2.42%,Noc-all 为 2.24%,在

1080Ti GPU 服务器上处理一张图片的平均时间为 0.45 s。本文提出模型的精度仅比 PSM-Net 低 0.10%,但是 PSM-Net 的参数总量为  $5.2 \times 10^6$ ,比本文所提出的网络模型参数多出 17%。对比 GC-Net,视差图的误匹配率降低了 0.45%,并且运行速度提升了一倍。

为了更加突出本文所提出算法在低纹理以及遮挡区域的匹配效果,与 GC-Net 进行了对比。如图 2 所示,从上往下依次为左视图、视差图和错误图。可以看出在一些低纹理区域(如车窗)的匹配效果本文算法明显优于 GC-Net,而且对物体边缘轮廓的展现更加精确。




图 2 对 KITTI2015 测试平台上图片 5 的效果展示

此外,本文对所提出的 ASPP 模块做了对比实验,实验结果如表 3 所示。

表 3 基于 KITTI2015 平台 ASPP 模块对精度的影响

| 网络模型    | All-all/% | Noc-all/% | 参数总量              |
|---------|-----------|-----------|-------------------|
| 含 ASPP  | 2.42      | 2.24      | $4.3 \times 10^6$ |
| 不含 ASPP | 2.57      | 2.37      | $3.7 \times 10^6$ |

从实验结果分析来看,ASPP 模块通过多尺度提取特征,充分获取了图像的上下文信息,将视差图的错误率降低了 0.15%,网络模型的参数增加了 14%。

#### 4 结论

本文介绍了一种基于卷积神经网络的立体匹配算法的实现。重点介绍了空洞金字塔池化(ASPP)模块,通过实验证明了 ASPP 模块能够有效提升视差图的精度。所提出的网络模型通过利用多尺度的 3D 卷积神经网络,能够大大减少参数总量,从而降低模型规模。最终的实验结果表明在 KITTI2015 测试平台下,本文的算法精度相较于 GC-Net 提升了 0.45%,对低纹理和遮挡等区域的匹配效果起到了相应的提升作用。

#### 参考文献

- [1] SCHARSTEIN D, SZELISKI R. A taxonomy and evaluation of dense two-frame stereo correspondence algorithms[J]. International Journal of Computer Vision, 2002, 47(1-3): 7-42.
- [2] TERZOPOULOS D. Regularization of inverse visual problems involving discontinuities[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986(4): 413-424.
- [3] YURTKULU S C, ŞAHİN Y H, UNAL G. Semantic segmentation with extended DeepLabv3 architecture[C]. 2019 27th Signal Processing and Communications Applications Conference (SIU), Sivas, Turkey, 2019: 1-4.
- [4] ZBONTAR J, LECUN Y. Stereo matching by training a convolutional neural network to compare image patches[J]. Journal of Machine Learning Research, 2016, 17(1): 1-32.
- [5] MENZE M, GEIGER A. Object scene flow for autonomous vehicles[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, 1: 3061-3070.
- [6] LUO W, SCHWING A G, URTASUN R. Efficient deep learning for stereo matching[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, 2: 5695-5703.
- [7] SEKI A, POLLEFEYS M. SGM-Nets: semi-global matching with neural networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [8] MAYER N, ILG E, HAUSSE P, et al. A large dataset to train convolutional networks for disparity, optical flow, and scene flow estimation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [9] PANG J H, SUN W X, REN J S, et al. Cascade residual learning: a two-stage convolutional neural network for stereo matching[C]. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017, 1: 878-886.
- [10] KENDALL A, MARTIROSYAN H, DASGUPTA S, et al. End-to-end learning of geometry and context for deep stereo regression[C]. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017.
- [11] CHANG J R, CHEN Y S. Pyramid stereo matching network[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, 2018: 5410-5418.

(下转第 21 页)

实验结果显示,随着近邻用户数量的增加,两种推荐算法的平均绝对误差 MAE 均呈现下降趋势,并趋于平稳。其原因是近邻用户数量增加时,推荐计算参考的用户也增多,精准度也逐渐上升。本文提出的融合算法比传统算法更稳定,随着近邻用户数量的增加,平均绝对误差逐渐降低,最高降低了 26.9%,而当近邻用户较少时,推荐质量也优于传统的协同过滤算法,这表明融合算法在一定程度上可以缓解传统推荐算法的冷启动问题。

#### 4 结束语

本文对比分析了传统协同过滤算法中常用的四种用户相似度计算,在指出其不足的基础上进行改进。充分考虑冷门物品对度量用户兴趣特征的贡献,引入了物品热门惩罚因子;增大最近物品对用户兴趣影响的权重,以反映用户兴趣的动态变化,提出了基于时间数据权重的非线性遗忘函数。进一步提出了基于惩罚因子和时间权重的用户相似度融合算法,实验结果表明,平均绝对误差(MAE)减小幅度较大,可更好地发现用户的兴趣,进行更有效的推荐,克服了传统算法的不足。

该算法引入了物品热门惩罚因子和时间权重,在提高准确率的同时,也增加了计算的复杂。未来的研究方向包括以下两个方面:其一,在不降低推荐精度的前提下提高推荐的广度,以便减少用户的审美疲劳,防止推荐马太效应;其二,进行画像分析,为用户提供更好的个性化推荐服务。

#### 参考文献

- [1] 赵小文. 基于协同过滤的推荐算法研究[D]. 西安:西安电子科技大学,2019.
- [2] 于洪,李转运. 基于遗忘曲线的协同过滤推荐算法[J]. 南京大学学报(自然科学版),2010,46(5):520-527.
- [3] 赵文涛,成亚飞,王春春. 基于 Logistic 时间函数和用户特征的协同过滤算法[J]. 计算机应用与软件,2017,34(2):285-289,312.
- [4] 兰艳,曹芳芳. 面向电影推荐的时间加权协同过滤算法的研究[J]. 计算机科学,2017,44(4):295-301,322.
- [5] 谢修娟,莫凌飞,李香菊,等. 融合位置信息和物品流行度的协同过滤算法[J]. 河海大学学报(自然科学版),2019,47(6):568-573.
- [6] 孙红,韩震. 融合物品热门因子的协同过滤改进算法[J]. 小型微型计算机系统,2018,39(4):638-643.
- [7] AHN H J. A new similarity measure for collaborative filtering to alleviate the new user cold-starting problem[J]. Information Sciences,2008,178(1):37-51.
- [8] 焦富森,李树青. 基于物品质量和用户评分修正的协同过滤推荐算法[J]. 数据分析与知识发现,2019,3(8):62-67.
- [9] JANNACH D,ZANKER M,FELFEMIG A,et al. Recommender systems:an introduction[D]. Cambridge:CUP,2010.

(收稿日期:2020-03-20)

#### 作者简介:

刘超慧(1981-),男,硕士,副教授,主要研究方向:富媒体资源推荐。

(上接第 5 页)

- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2016:770-778.

(收稿日期:2020-03-11)

#### 作者简介:

鲁志敏(1994-),男,硕士研究生,主要研究方向:立体

视觉与数字电路设计。

袁勋(1995-),男,硕士研究生,主要研究方向:立体视觉与集成电路工程。

陈松(1979-),通信作者,男,博士,副教授,主要研究方向:VLSI 计算机辅助/架构体系设计、立体视觉算法与系统设计。E-mail:songch@ustc.edu.cn。

# 版权声明

经作者授权，本论文版权和信息网络传播权归属于《信息技术与网络安全》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《信息技术与网络安全》编辑部  
中国电子信息产业集团有限公司第六研究所