光电技术及应用

DOI：10.16818/j.issn1001－5868.2021.01.017

基于差分卷积的自适应视线估计

罗　元*，陈　旭，欧俊雄

（重庆邮电大学 光电工程学院，重庆 400065）

摘　要： 文章提出了一种基于差分卷积神经网络的自适应视线估计模型。在模型中，融入头部姿态信息，利用差分卷积设计了一种差分网络（Differential Network，DNet），通过训练该网络来预测眼睛的凝视差异，用以校准初步视线估计结果，进而降低视线估计误差。通过在公开数据集Eyediap上进行验证，并与其他性能良好的视线估计模型进行比较，结果均表明所提出的视线估计模型在头部自由运动的状态下可以更准确地估计视线方向。

关键词： 视线估计；差分卷积；头部姿态

中图分类号： TP391.41　**文章编号：** 1001－5868(2021)01－0093－07

Adaptive Gaze Estimation Based on Differential Convolution

LUO Yuan，CHEN Xu，OU Junxiong

（College of Optoelectronic Engineering，Chongqing University of Posts and Telecommunications，Chongqing 400065，CHN）

Abstract： An adaptive model is proposed for gaze estimation based on differential convolutional neural network. The adaptive model incorporates information of head pose and designs a network named Differential Network (DNet) by virtue of differential convolution. The DNet is trained to predict gaze differences in the eyes，calibrate the initial gaze estimations and thus reduce the estimation errors. Through validation on the publicly available dataset Eyediap and comparison with other well-performed gaze estimation models developed in recent years，the experimental results indicate that the proposed adaptive model can estimate gaze directions more accurately under free head movement.

Key words： gaze estimation；differential convolution；head pose

0　引言

随着计算机视觉、人工智能等领域的高速发展，视线估计技术的研究引起了广泛的关注。视线是分析人类行为和心理状态的一种十分重要的非语言线索，是人注意力与兴趣的表现之一，视线信息有助于推断人的内心状态或意图，可以帮助更好地理解个体之间的互动。因此，视线估计在很多研究领域都发挥着重要的作用，如：人机交互、虚拟现实、社会交互分析、智慧医疗等。

广义的视线估计泛指对于眼球、眼动、视线等相关的研究。一般来说，视线估计方法可以分为基于模型的方法和基于表观的方法两大类[1]。基于模型的方法[2]的基本思想是基于眼睛角膜反射等特征，结合3D眼球先验知识，估计视线方向。而基于表观的方法[3]则是直接提取眼睛的视觉特征，训练回归模型，学习一个将外观映射到视线方向的模型，从而进行视线估计。通过对比分析，基于模型的方法获得的精度较高，但对图片的质量和分辨率要求也较高，为了达到这一目的，通常要求使用专门的硬件，且对用户的头部姿态等移动性限制很大；而基于表观的方法对低分辨率和高噪声的图像表现更好，但其模型的训练需要大量数据，并且容易出现过拟合现象。随着深度学习的发展以及大量数据集的公开，基于表观的方法受到越来越多关注。

收稿日期：2020－08－16.

基金项目：国家自然科学基金项目(61801061).

* **通信作者：**罗　元　**E-mail：** luoyuan@cqupt.edu.cn

2015 年，Zhang 等[4]最早尝试使用神经网络来做视线估计，其采用单眼图像作为输入，利用 LeNet 的浅层网络进行学习，并将头部姿态信息与提取到的眼睛特征拼接进行视线估计，最终在 MPIIGaze 数据集上得到 6.3°的误差。2017 年，Zhang 等[5]又提出了基于注意力机制的全脸视线估计方法，该方法利用注意力机制增大眼睛区域的权重，抑制其他与凝视无关的区域的权重，采用端到端的学习策略，直接得到相机坐标系下的视线方向。同年，Deng 等[6]也发表了对全脸视线估计的研究成果，其方法要求同时输入人脸与人眼两个图像，提出将一个凝视的几何变换层用于头部姿态与人脸坐标系下的凝视进行几何解析，最终获得相机坐标系下的凝视方向。2018 年，Cheng 等[7]提出了一种基于双眼的非对称回归方法，该方法以双眼图像作为输入，充分利用了双眼的互补信息，经过非对称回归网络（AR-Net）与评价网络（E-Net）两个模块进行训练学习，进而实现视线估计。同年，Park 等[8]提出了一种基于眼睛图形表示的视线估计方法，他们通过深度网络将眼睛抽象为一个眼球图形表示来提升视线估计的精度，其中，眼球图形表示这一监督信号是由视线的真实值经几何方法反推生成的。Yu 等[9]也在同年基于多任务学习的思想提出了一种基于约束模型的视线估计方法，该方法在估计视线的同时检测眼睛关键点位置，两个任务同时学习，信息互补，可以在一定程度上得到共同提升，实验证明该模型取得了比直接回归方法更准确的结果。目前，虽然对视线估计技术的研究取得了很大的进步，但由于个体之间眼睛形状和眼内结构的差异性，通用模型获得的精度有限，同时，用户头部的移动幅度会对实验结果产生较大影响，降低识别精度。

为了解决上述问题，本文提出了一种基于差分卷积的自适应视线估计方法。在所设计的模型中，融入头部姿态信息，设计差分网络（DNet），训练该网络预测眼睛的凝视差异，用以校准初步视线估计结果，从而实现更为准确的视线估计。在 Eyediap 数据集中进行了实验，结果表明差分卷积网络可以降低估计误差，本文提出的模型可实现更为准确的视线估计。

1 基于卷积神经网络的视线估计

基于表观的视线估计算法有很多种，其中基于卷积神经网络的视线估计算法成为了近年来研究的重要方向之一。主要原因在于其稳定性与准确率在基于表观的视线估计方法中均表现出了良好的效果，但其准确率仍不能满足实用的要求，还需要进一步的提高。

卷积神经网络是一种比较特殊的人工神经网络，通常由卷积层、池化层和全连接层组成。

（1）卷积层

卷积层主要通过卷积运算来提取图像特征。每个卷积层由多个二维平面构成，这些二维平面经过不同的卷积核对前一层进行卷积操作形成特征图谱，进而实现输入特征的层层传播。假设当前层为 i 层，则第 j 层的特征图公式为

$$x_j^i = \sum_{n \in M} x_n^{i-1} \otimes k_{nj}^i + b_j^i \tag{1}$$

其中，x_n^{i-1} 为第 $i-1$ 层的第 n 个特征图，$\otimes$ 为卷积操作，k_{nj}^i 为卷积核，b_j^i 是第 i 层的第 j 个特征图的偏置，M 为当前特征图的上层特征图的集合。

（2）池化层

池化层也称下采样层，通常设置在卷积层之后，用于下采样特征响应图的局部区域。通过对不同位置的特征求取平均值或最大值来进行聚类分析，以达到对输入图像降维的目的，进而实现在降低计算量的同时避免过拟合现象发生。常见的池化公式为

$$x_j^i = \beta_j^i \cdot \mathrm{down}(x_j^{i-1}) + b_j^i \tag{2}$$

其中，β_j^i 和 b_j^i 分别表示第 $i-1$ 层和 j 个特征图的乘子偏差和附加偏差，down(·)是降维采样函数，可以采用最大池化或者平均池化。

（3）全连接层

全连接层将卷积层和池化层提取到的特征图谱相连，使每个输入与输出的神经元产生联系，从而最大程度地表示全局特征，然后有针对性地将提取出的特征表示映射到样本标记空间，进行回归任务。

常用的基于卷积神经网络的视线估计网络构架主要由三个卷积层和两个全连接层组成[10]，网络结构如图 1 所示。将 3@48×72 的眼睛图像 I 作为输入，其中 3 表示眼睛图像的通道数，48×72 表示眼睛图像的大小。对图像进行预处理后，应用到卷积层，并将得到的特征图谱输入全连接层，最后在全连接层通过训练一个线性回归得到视线方向 $g_p(I)$。

对于损失函数，用 $g_{gt}(I)$ 表示眼睛注视的真实值，则损失函数 L 可表示为

$$L = \frac{1}{|D|} \sum_{I \in D} \| g_p(I) - g_{gt}(I) \|_1 \tag{3}$$

其中，D 为训练数据集，$|\cdot|$ 为基数运算符。

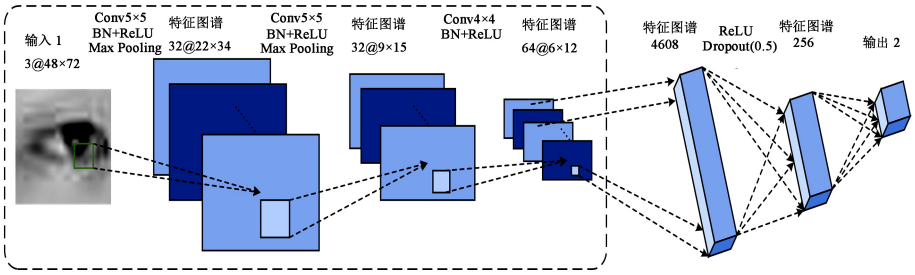
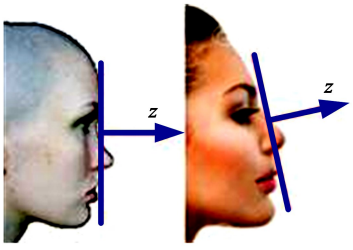
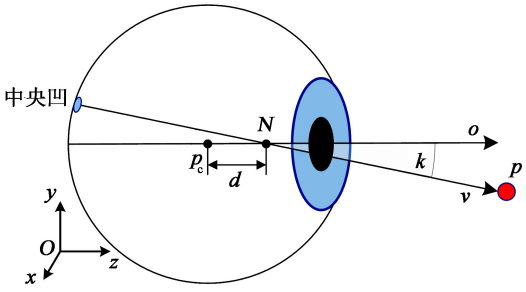


图 1　基于卷积神经网络的视线估计

通过分析可知，直接采用上述方法进行的视线估计对双眼的互补信息没有充分利用，而且在头部自由运动的情况会对视线估计结果造成较大影响。同时，个体之间眼睛形状和眼内结构的差异，会导致相同外观但内部眼球结构不同的两只眼睛的图像可以对应不同的凝视方向，如图 2 所示。



(a) 头部姿态变化



(b) 眼球内部成像模型

图 2　影响视线估计结果因素示例

从图 2(a)可以看出，头部姿态的变化会引起不同的额头姿势定义，进而导致眼睛图像的变化，对视线的估计产生影响。对于图 2(b)，p 为注视点，v 表示视轴，o 表示光轴，p_c 是眼球中心，中心凹是视网膜上对光敏感度最高的一个点，N 则代表一个与眼球中心距离为 d 的节点。大多数情况下，会把光轴看做视线，但事实上，视线是注视点 N 与中央凹的连线。用 k 来表示真实视线与光轴的夹角，k 的大小因人而异，由人眼内部结构决定，是无法从图像中获取的，故会对视线估计的精度产生影响[11]。针对以上问题，为了更准确地进行视线估计，本文对基于卷积神经网络的视线估计模型进行改进，充分利用双眼信息，融合头部姿态特征，改进网络结构，并设计基于差分卷积的 DNet 网络对视线估计结果进行校准。

2　基于差分卷积的视线估计

为了解决因用户眼睛的个性化影响视线估计准确性的问题，本文设计了基于差分卷积的 DNet 网络视线估计模型进行自适应的视线估计。如图 3 所示，其主要部分是一个预训练的差分网络，可以预测同一只眼睛的两幅图像之间的凝视差异。即在训练过程中，使用来自同一只眼睛的随机样本对来训练差分网络。在测试时，给定一组参考样本，计算注视量差异，并利用注视量差异推断输入图像的注视量。为了获得更高的精度，差分网络可以通过微调参考样本对来适应。

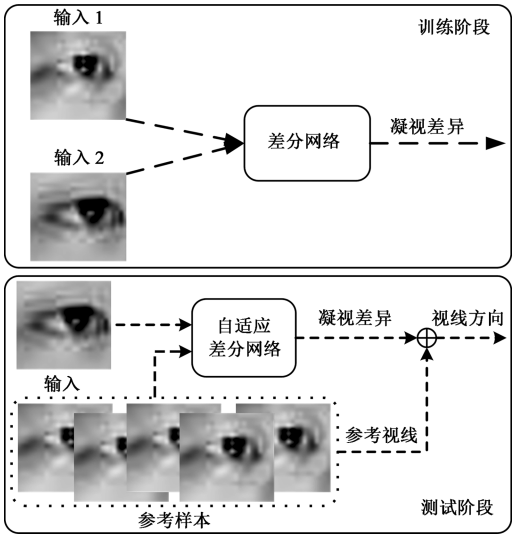


图 3　方法概述图

2.1　差分卷积网络

如前所述，卷积层主要通过卷积运算来提取图像特征，卷积技术的中心思想是考虑样本与其相邻

样本的有向变化。而差分卷积是分析某个样本与相邻样本的模式方向，差分计算通过计算样本激活间的差异来反映连续样本的变化[12]。

本文采用差分卷积的方法，对同一只眼睛的两张特征图，运用预设的常量滤波器从其特征图产生附加的差分图。通常，运用的 4 个常量滤波器每个滤波器计算一个方向的差分值，最终特征图会包含 4 个方向的差分值。设传统卷积生成的特征图为 d_1，4 个附加的特征图为 d_2，d_3，d_4 和 d_5，相对的神经元计算方法分别为

$$d_{2,i,j}=d_{1,i,j}-d_{1,i+1,j} \tag{4}$$

$$d_{3,i,j}=d_{1,i,j}-d_{1,i,j+1} \tag{5}$$

$$d_{4,i,j}=d_{1,i,j}-d_{1,i+1,j+1} \tag{6}$$

$$d_{5,i,j}=d_{1,i+1,j}-d_{1,i,j+1} \tag{7}$$

如果 d_1 的大小为 $M\times N$，d_2，d_3，d_4 和 d_5 的大小分别为 $(M-1)\times N$，$M\times(N-1)$，$(M-1)\times(N-1)$ 和 $(M-1)\times(N-1)$。附加特征以 0 填充，扩展到第 1 个特征图的大小，如图 4 所示。

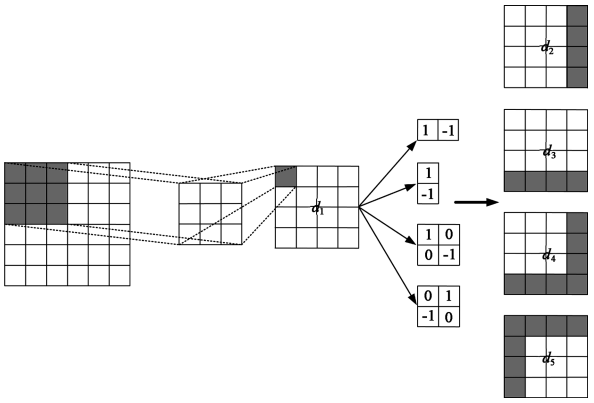


图 4 差分特征图的扩展示意图

2.2 基于差分卷积的 DNet 网络

为使视线估计的结果更加准确，本文设计了基于差分卷积的 DNet 网络。首先，以全脸图像作为输入，经过预处理，利用左右眼特征和头部姿态特征进行视线初估计，然后采用基于差分卷积网络对初步视线估计结果进行校准，以达到准确估计视线方向的同时，提高头部姿态鲁棒性的目的。整体网络架构如图 5 所示。

其中，差分卷积网络部分采用并行的结构，而并行结构的每个分支都由 3 个卷积层组成，每个卷积层都经过批处理归一化和 ReLU 单元。在第一层与第二层后应用最大池化，以缩小图像尺寸。在第三层后，将两张输入图像的特征图进行归一化处理并拼接成一个新的张量。然后在张量上应用两个全连接层来预测两张输入图像的凝视差异，用于视线的校准。

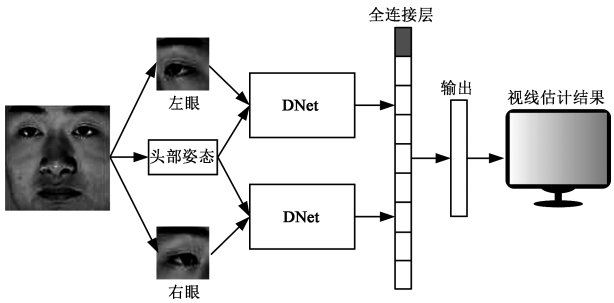


图 5 整体网络框架

本文选择 ReLU 函数作为卷积层和全连接层的激活函数，因为相对于 tanh 函数、sigmoid 函数等激活函数，ReLU 函数收敛速度更快，具有克服梯度消失、加快模型的训练速度以及更好地防止模型过

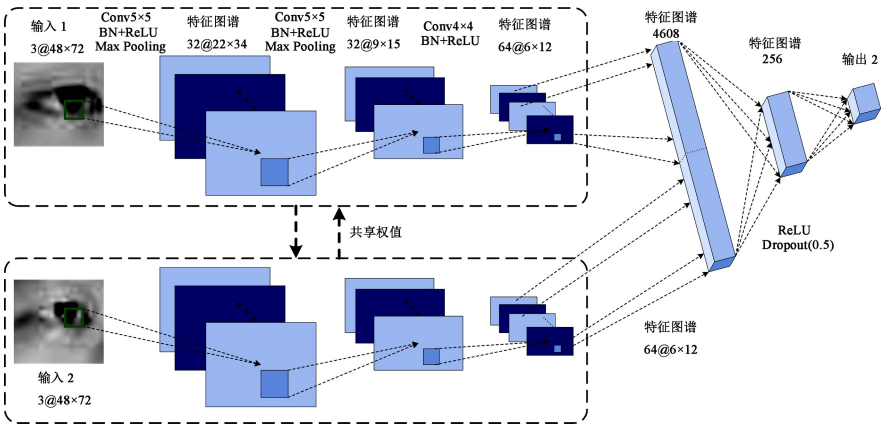


图 6 差分卷积网络结构

拟合的特性。其公式表示为

$$f(x)=\max(0,x) \tag{8}$$

其中，x 是输入，$f(x)$ 是经过 ReLU 单元之后的输出。

对于损失函数，用 $d^{\mathrm{p}}(I,J)$ 表示差分网络预测的凝视差异，则损失函数 L_{d} 为

$$L_{\mathrm{d}}=\sum_{I,J\in D^{k}}\left\|d^{\mathrm{p}}(I,J)-(g_{\mathrm{gt}}(I)-g_{\mathrm{gt}}(J))\right\|_{1} \tag{9}$$

其中，D^{k} 为训练集 D 的子集，只包含第 k 个人的一只眼睛的图像。

通过差分卷积网络来预测测试图像 I 与参考图像 F 之间的差异 $d^{\mathrm{p}}(I,J)$，并结合真实的注视值 $g_{\mathrm{gt}}(F)$来预测最终的视线方向 $g_{\mathrm{gt}}(F)+d^{\mathrm{p}}(I,J)$，公式为

$$g_{\mathrm{sm}}(I)=\frac{\sum_{F\in D_{\mathrm{c}}}w(d^{\mathrm{p}}(I,J)\cdot(g_{\mathrm{gt}}(F)+d^{\mathrm{p}}(I,J)))}{\sum_{F\in D_{\mathrm{c}}}w(d^{\mathrm{p}}(I,J))} \tag{10}$$

其中 $w(\cdot)$是对每个预测的重要性进行加权。

由上式可知，参考图像与测试图像更相似，得到的结果会更为准确。在实验时，会得到参考图像的校准集 D_{c}，故可以通过选择一对样本 $(I,J)\in D_{\mathrm{c}}$ 应用相同的损失函数对网络进行微调，以达到自适应的目的。

3　实验分析

3.1　数据集

本文选择在公开数据集 Eyediap[13] 上验证提出的视线估计模型。Eyediap 数据集包含了来自 16 个参与者的 94 个视频。视频分为三大类：连续屏幕(CS)目标、离散屏幕(DS)目标和浮动目标(FT)。记录的视频序列主要包含头部姿态、注视点、参与者、记录条件(不同的天气、光照、到相机的距离)四种变量。具有两种头部姿态、静止状态和执行平移或旋转的运动状态。本文实验中使用了 CS 视频，其中包括静态姿态(SP，受试者在看目标时大致保持相同的姿态)和动态姿态(MP，受试者在看目标时执行额外的重要头部动作)。本文对 Eyediap 数据集按 5 f/s 提取一张图片，去掉眼睛闭合的图片，共在 Eyediap 数据中提取 86 000 张图片。

3.2　实验评价指标

本文在 Eyediap 数据集上使用角误差 ε 作为性能评价指标，角误差的定义为真实视线方向和估计视线方向之间的夹角，公式为

$$\varepsilon=\frac{1}{N}\sum_{i}^{N}\arccos\frac{\langle g_{i},g_{j}\rangle}{|g_{i}||g_{j}|} \tag{11}$$

其中，$|g_{i}||g_{j}|$是 g_{i} 和 g_{j} 的内积，ε 的单位是度，其值越小，表示模型估计误差越低。

3.3　预处理

在训练模型时，将在原始图像上利用瞳孔坐标裁剪的眼睛图像和给定的头部姿态作为输入。在测试时，本文采用文献[14]中的先验多任务级联卷积神经网络(Multi-Task Cascaded Convolutional Networks，MTCNN)算法进行人脸检测与瞳孔中心定位。先验 MTCNN 算法可以在进行人脸检测的同时得到 5 个人脸面部特征点(左右瞳孔、左右嘴角、鼻尖)，该算法对于非约束环境如光强、角度和人脸表情等变化均显现出良好的鲁棒性。然后为得到矫正的人脸图像，利用面部特征点对人脸区域进行仿射变换，在矫正的人脸图像中根据新的瞳孔坐标设定眼睛大小的阈值从而得到人眼区域，最后将双眼图像进行尺度变换运用到下一部分。此外，为了提高模型对头部运动的鲁棒性、减少网络运行时间，本文采用文献[15]中的方法直接利用人脸图像估计出头部姿态。

3.4　实验结果与分析

本文将提取到的图像随机分成两个部分，70% 的数据用于训练构成训练集，30% 的数据用于测试构成测试集，以实现训练与测试数据集完全不相交，避免出现过拟合现象。同时，由于数据库相对较小，故采用对训练集图像进行几何变换、加入高斯噪声、改变图像对比度三种数据增强的方式以增加训练数据集。

为简化网络结构，本文选定 LeNet 作为视线初步估计的网络框架，然后分别对有无差分网络、有无头部姿态四种情况排列组合进行网络测试，记录其训练损失函数变化与角误差变化，结果如表 1 所示。为更加清晰地展示二者的变化与不同情况的对比，本文对变化曲线进行拟合处理，结果如图 7、图 8 所示。

由以上分析可知，当只利用 LeNet 网络进行基于卷积神经网络的视线估计时，得到的角误差为 10.01°；当利用 LeNet 网络并融合头部姿态信息 h 时，得到的角误差为 6.43°；当利用 DNet 网络进行基于差分卷积的视线估计时，得到的角误差为 5.57°；当利用 DNet 网络并融合头部姿态信息 h 时，得到的角误差为 4.78°。通过对比以上数据可知，在缺少头部姿态时，视线估计的效果均较差，故头部姿态信息对视线估计的准确性有较大的影响；

更重要的是，可以看出本文设计的模型相对于其他三种情况，角误差最小，视线估计效果更好。

表 1 不同网络结构的角误差

结构	ε/(°)
LeNet	10.01
LeNet+h	6.43
DNet	5.57
DNet+h	4.78

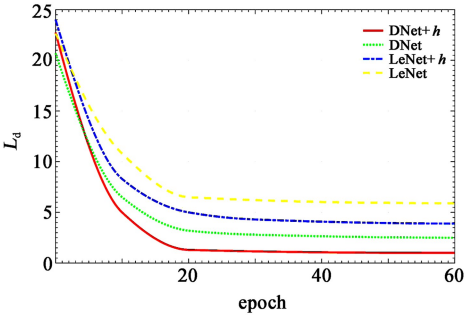


图 7 不同网络结构下训练损失函数变化对比图

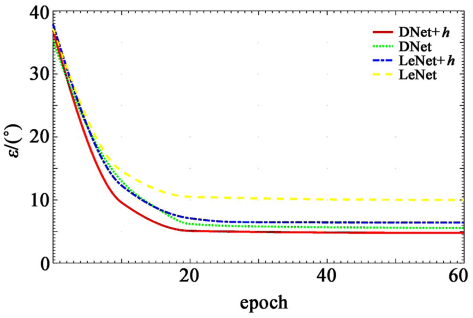


图 8 不同网络结构下误差变化对比图

为了更明确地进行不同模型对视线估计效果的对比，将本文提出的算法模型与其他基于卷积神经网络的视线估计方法进行对比，结果如表 2 所示。

表 2 不同方法视线估计的角误差

方法	ε/(°)
文献[9]	7.72
文献[4]	6.30
文献[7]	5.00
DNet	4.78

如表 2 所示，本文提出的视线估计方法具有最佳的性能，而文献[7]采用的基于双眼的非对称回归方法获得 5°的角误差排在第二位，与之相比，本文提出的融合头部姿态特征，并利用差分网络对初步视线估计结果进行校准的方法获得了更低的误差，实现了更为准确的视线估计。

4 结束语

本文针对于不同个体间眼睛形状和眼内结构存在差异，通用模型获得精度有限，且在头部自由运动的状态下，视线估计效果欠佳的问题，采用基于表观的视线估计方法，融合头部姿态信息，提出了一种基于差分卷积的自适应视线估计网络。在公开数据集上进行测试的实验结果表明，差分卷积的引入可以有效地校准视线估计结果，降低视线估计误差，并对头部姿态变化具有较好的鲁棒性。同时，与其他效果良好的视线估计方法进行对比，本文提出的模型仍具备更优越的性能。在后续的工作中，将针对面部遮挡变化、戴有眼镜、距离变化等情况下的视线估计进行更深入的研究。

参考文献：

[1] Hansen D W, Ji Q. In the eye of the beholder: A survey of models for eyes and gaze[J]. IEEE Trans. Pattern Anal. Mach. Intell., 2010, 32(3): 478-500.

[2] Fukuda T, Morimoto K, Yamana H. Model-based eye-tracking method for low-resolution eye-images[C]// Proc. of 2nd Workshop on Eye Gaze in Intelligent Human Machine Inter-action, 2011: 1-8.

[3] Martinez F, Carbone A, Pissaloux E. Gaze estimation using local features and non-linear regression[C]// Proc. of 19th IEEE Inter. Conf. on Image Processing, 2012: 1961-1964.

[4] Zhang X, Sugano Y, Fritz M, et al. Appearance-based gaze estimation in the wild[C]// Proc. of IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2015: 4511-4520.

[5] Zhang X, Sugano Y, Fritz M, et al. It's written all over your face: Full-face appearance-based gaze estimation[C]// Proc. of IEEE Conf. on Computer Vision and Pattern Recognition Workshops (CVPRW), 2017: 2299-2308.

[6] Deng H, Zhu W. Monocular free-head 3D gaze tracking with deep learning and geometry constraints[C]// Proc. of 2017 IEEE Inter. Conf. on Computer Vision (ICCV), 2017: 3162-3171.

[7] Cheng Y, Lu F, Zhang X. Appearance-based gaze estimation via evaluation-guided asymmetric regression: 15th European Conf., Munich, Germany, September 8-14, 2018, Proceedings, Part XIV[C]// Proc. of European Conf. on Computer Vision, 2018: 105-121.

[8] Park S, Spurr A, Hilliges O. Deep pictorial gaze estimation [C]// Proc. of European Conf. on Computer Vision (ECCV), 2018: 741-757.

[9] Yu Y, Liu G, Odobez J M. Deep multitask gaze estimation with a constrained landmark-gaze model [C]// Proc. of European Conf. on Computer Vision, 2018: 456-474.

[10] Mora K A F, Odobez J M. Geometric generative gaze estimation (G3E) for remote RGB-D cameras[C]// Proc. of IEEE Conf. on Computer Vision & Pattern Recognition, 2014: 1773-1780.

[11] Liu G, Yu Y, Funes Mora K A, et al. A differential approach for gaze estimation[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2021, 43(3): 1092-1099.

[12] 任佳丽，王文晶. 基于差分孪生卷积神经网络的大规模不平衡数据分类算法[J]. 计算机应用与软件，2019，36(11)：267-274.
Ren Jiali, Wang Wenjing. Large-scale unbalanced data classification algorithm based on differential twin convolutional neural networks[J]. Computer Applications and Software, 2019, 36(11): 267-274.

[13] Mora K A F, Monay F, Odobez J M. EYEDIAP: a database for the development and evaluation of gaze estimation algorithms from RGB and RGB-D cameras[C]// Proc. of the Symposium on Eye Tracking Research and Applications. ACM, 2014: 255-258.

[14] Luo Yuan, Chen Xuefeng, Chen Xu, et al. Visual focus of attention estimation based on improved hybrid incremental dynamic Bayesian network[J]. Optoelectron. Lett., 2020, 16(1): 45-51.

[15] Ruiz N, Chong E, Rehg J M. Fine-grained head pose estimation without keypoints[C]// Proc. of 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition Workshops (CVPRW), 2018: 2074-2083.

作者简介：

罗　元(1972—)，女，博士，教授，主要研究领域为数字图像处理和智能信号处理。

(上接第 75 页)

4　结论

本文基于 PIND 试验中的电压采样数据，建立了多余物颗粒检出概率的模型，利用该模型研究了空封光电耦合器内同等质量的典型颗粒的分布区域、试验频率与检出概率的关系。实验结果表明在所研究的器件结构中，陶瓷颗粒的检出概率主要受碰撞对象硬度的影响，从而在不同区域中差异很大，且与坚硬陶瓷板碰撞时的检出概率很小；导电胶的检出概率主要受粘附性的影响，在碰撞对象表面光滑、试验频率高时相对较大，但受自身弹性弱的影响，整体上检出概率仍偏小；短金丝则由于粘附性弱、弹性强，检出概率大且稳定。据此，结合颗粒质量的随机性，提出了对典型多余物颗粒的控制与检测方法，以有效地提高空封光电耦合器的可靠性水平。所用模型和研究方法可推广至其他空封元器件的多余物检出概率研究中。

参考文献：

[1] 关亚男，裴志强，刘春芝，等. 浅析封装腔体内自由粒子的产生及控制[J]. 微处理机，2008，29(1)：9-13.
Guan Yanan, Pei Zhiqiang, Liu Chunzhi, et al. An analysis of particles production and control in the package [J]. Microprocessors, 2008, 29(1): 9-13.

[2] 郭　伟，葛秋玲. 气密性陶瓷封装 PIND 失效分析及解决方案[J]. 电子与封装，2007，7(11)：1-4.
Guo Wei, Ge Qiuling. PIND failure analysis of air-tightness ceramic packaging and the solutions [J]. Electronics & Packaging, 2007, 7(11): 1-4.

[3] 吴维丽，王瑞曾，金毓铨. PIND 试验的特殊属性和适用范围研究[J]. 信息技术与标准化，2012(9)：68-70.
Wu Weili, Wang Ruizeng, Jin Yuquan. Research for particularity and applicable scope of PIND[J]. Information Technology & Standardization, 2012(9): 68-70.

[4] 陈亚兰，肖　玲. 混合集成电路 PIND 试验特征波形研究及控制方法[J]. 微电子学，2010，40(1)：153-156.
Chen Yalan, Xiao Ling. Study on PIND characteristic pulse of hybrid IC's and its control methods[J]. Microelectronics, 2010, 40(1): 153-156.

[5] 杜　迎，张国华，朱卫良，等. 可靠性试验粒子碰撞噪声检测技术研究[J]. 电子与封装，2006，6(5)：33-39.
Du Ying, Zhang Guohua, Zhu Weiliang, et al. IC failtests technical study of particle impact noise detection testing[J]. Electronics & Packaging, 2006, 6(5): 33-39.

[6] 钱　鑫，王国涛，王淑娟. 密封电子元件及设备多余物的 PIND 方法研究进展[J]. 航天制造技术，2016(6)：1-5.
Qian Xin, Wang Guotao, Wang Shujuan. Development of PIND detection methods for sealed electronic components and equipments[J]. Aerospace Manufacturing Technol., 2016(6): 1-5.

[7] 杜　迎，吕　栋，潘伟力，等. 粒子碰撞噪声检测(PIND)试验的研究[J]. 电子产品可靠性与环境试验，2005(1)：34-39.
Du Ying, Lv Dong, Pan Weili, et al. Study of particle impact noise detection (PIND)[J]. Electronic Product Reliability and Environmental Testing, 2005(1): 34-39.

[8] 李　冰，李刚华，赵瑞莲，等. PIND 波形尖峰数与多余物特性关系的研究[J]. 半导体光电，2019，40(2)：243-246.
Li Bing, Li Ganghua, Zhao Ruilian, et al. Relationship between spiking number of PIND waveform and characters of remainder[J]. Semiconductor Optoelectronics, 2019, 40(2): 243-246.

作者简介：

李　冰(1982—)，男，2005 年毕业于北京工业大学微电子学与固体电子学专业，获硕士学位，高级工程师，主要从事光电器件工艺研究。