



# 计算机科学

COMPUTER SCIENCE

## 基于虹膜纹理感知的自适应关联学习方法

孔佳琳, 张琪, 卫建泽, 李琦

引用本文

孔佳琳, 张琪, 卫建泽, 李琦. 基于虹膜纹理感知的自适应关联学习方法[J]. 计算机科学, 2025, 52(4): 185-193.

KONG Jialin, ZHANG Qi, WEI Jianze, LI Qi. [Adaptive Contextual Learning Method Based on Iris Texture Perception](#) [J]. Computer Science, 2025, 52(4): 185-193.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [基于多尺度融合注意力的多视角文档图像篡改检测与定位](#)

Multi-view and Multi-scale Fusion Attention Network for Document Image Forgery Localization

计算机科学, 2025, 52(4): 327-335. <https://doi.org/10.11896/jsjcx.240100142>

### [输入感知的通用矩阵-向量乘算法在Hygon DCU的自适应性能优化](#)

Input-aware Generalized Matrix-Vector Product Algorithm for Adaptive Performance Optimization of Hygon DCU

计算机科学, 2025, 52(4): 291-300. <https://doi.org/10.11896/jsjcx.241100030>

### [大选择性核双边网络的长尾分布医学图像分类方法](#)

Long-tail Distributed Medical Image Classification Based on Large Selective Nuclear Bilateral-branch Networks

计算机科学, 2025, 52(4): 231-239. <https://doi.org/10.11896/jsjcx.240700039>

### [面向无人机航拍图像的YOLOv8目标检测改进算法](#)

An Improved YOLOv8 Object Detection Algorithm for UAV Aerial Images

计算机科学, 2025, 52(4): 202-211. <https://doi.org/10.11896/jsjcx.240500042>

### [基于YOLO-Unet组合网络的牛只个体识别方法研究](#)

Research on Individual Identification of Cattle Based on YOLO-Unet Combined Network

计算机科学, 2025, 52(4): 194-201. <https://doi.org/10.11896/jsjcx.240100144>

# 基于虹膜纹理感知的自适应关联学习方法

孔佳琳<sup>1</sup> 张琪<sup>1</sup> 卫建泽<sup>2</sup> 李琦<sup>3</sup>

1 中国人民公安大学信息安全学院 北京 100038

2 中国科学院微电子研究所 北京 100029

3 中国科学院自动化研究所 北京 100190

(lynn00660@163.com)

**摘要** 虹膜中的微结构具有较高的个体区分度,使得虹膜识别成为实现身份验证的理想选择。除了微结构本身的特征外,其间的关联性也是用于身份验证的有效判别线索。针对虹膜微结构之间的关联性,提出了一种基于虹膜纹理感知的自适应关联学习方法,该方法在关联测度模型的双分支结构基础上进行改进,融入了通道注意力和高效多尺度注意力机制来自适应地动态调整特征图,从不同细节层次的分布中捕捉特征,提高了对虹膜微结构的敏感度。为了深入挖掘来自全局和局部特征之间的关联作用,利用注意力机制对双分支网络提取到的特征进行自适应加权融合,这种加权方式可以根据输入的重要性或相关性灵活地分配不同的权重以学习最优特征关联。实验结果表明,自适应关联学习方法在虹膜识别任务中的表现出色,在多项评价指标上优于现有基线方法,具有更高的识别精度和更强的泛化能力。

**关键词**: 虹膜识别; 生物特征识别; 深度学习; 注意力机制; 自适应

**中图分类号** TP391.41

## Adaptive Contextual Learning Method Based on Iris Texture Perception

KONG Jialin<sup>1</sup>, ZHANG Qi<sup>1</sup>, WEI Jianze<sup>2</sup> and LI Qi<sup>3</sup>

1 School of Information and Cyber Security, People's Public Security University of China, Beijing 100038, China

2 Institute of Microelectronics, Chinese Academy of Sciences, Beijing 100029, China

3 Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China

**Abstract** The microstructures in the iris exhibit a high degree of individual distinctiveness, making iris recognition an ideal choice for identity verification. In addition to the characteristics of the microstructures themselves, the context among them also serves as an effective cue for identity verification. To address the correlations between iris microstructures, an adaptive contextual learning method based on iris texture perception is proposed. This method improves upon the dual-branch structure of contextual measures model by incorporating channel attention and efficient multi-scale attention mechanisms. These mechanisms dynamically adjust the feature maps adaptively, capturing features from different levels of detail distribution and enhancing sensitivity to iris microstructures. To thoroughly explore the correlation between global and local features, attention mechanisms are employed to adaptively fuse the features extracted by the dual-branch network. This weighting approach flexibly assigns different weights based on the importance or relevance of the input, aiming to learn the optimal feature associations. The experimental results demonstrate that the adaptive contextual learning method performs excellently in iris recognition tasks, surpassing existing baseline methods across multiple evaluation metrics, with higher recognition accuracy and stronger generalization ability.

**Keywords** Iris recognition, Biometric recognition, Deep learning, Attention mechanism, Adaptive

## 1 引言

虹膜识别技术因虹膜精密复杂的生理结构而独树一帜。虹膜中的隐窝、斑点、冠状、细丝等构成了个体间独特的纹理

模式。这些纹理中,随机分布且形状不规则的微结构<sup>[1]</sup>具有高度的随机性和个体差异性,即使同卵双胞胎也存在显著差异。这些微结构特征为高精度身份认证提供了生物学基础。

早期虹膜识别传统方法基于手工特征提取,但易受眼睑

到稿日期:2025-01-03 返修日期:2025-02-17

基金项目:国家自然科学基金(61906199,62306307);中国博士后科学基金(2024T170985)

This work was supported by the National Natural Science Foundation of China(61906199,62306307) and China Postdoctoral Science Foundation(2024T170985).

通信作者:张琪(qi.zhang@ppsuc.edu.cn)

和睫毛遮挡影响导致识别准确率较低,因此部分研究转向微观结构,利用局部纹理差异进行身份识别。IrisCode<sup>[2-3]</sup>通过多尺度 Gabor 小波编码相位信息。Ma 等<sup>[4]</sup>利用小波检测局部锐变点捕捉纹理突变特征。除了视觉特征上的微观结构外,它们之间的关联性也是身份识别中有效的鉴别线索。虹膜微结构间的关联性主要是虹膜微结构区域之间在视觉模式和统计模式上的相似性。通过捕捉微结构间的关联性,可以提高虹膜识别系统的准确性和鲁棒性。Ordinal code<sup>[5]</sup>利用定序测量来描述虹膜纹理信息中的定性关系。IRINA<sup>[6]</sup>通过构建精细的控制点网格和 MRF(Markov Random Field)<sup>[7-8]</sup>,对虹膜图像中的微小变化和局部特征进行建模,以提高特征提取和图像配准的精度。

深度学习和注意力机制在图像识别领域表现出了卓越的性能,为虹膜识别技术的发展提供了新的契机<sup>[9-10]</sup>。卷积神经网络(Convolutional Neural Networks, CNN)通过逐层抽象机制实现了自动特征学习。基于深层网络对局部纹理的敏感性和全局特征的联系性,UniNet<sup>[11]</sup>使用全卷积网络(Fully Convolutional Network, FCN)生成空间对应的虹膜特征描述符;Maxout CNN<sup>[12]</sup>采用轻量架构和 Maxout 激活函数来提取紧凑且判别性强的深度特征,比传统的 AlexNet<sup>[13]</sup>和 VGG-16<sup>[14]</sup>模型参数更少,特征维度更低。而这些方法主要关注高级语义模式阶段的全局相关性,对于微结构的关联度并没有充分考虑,缺少对低级视觉模式的细粒度描述,导致虹膜图像失真或遮挡时泛化能力下降。

尽管 Ren 等<sup>[15]</sup>提出了 DGR(Dynamic Graph Representation),通过图结构学习虹膜微结构的长距离依赖关系,但其性能依赖区域选择且动态匹配耗时较长。考虑到微结构分布的随机性,Wei 等<sup>[16]</sup>提出了关联测度(Contextual Measures, CM)模型,基于“任意虹膜区域都可能包含微结构”的过饱和假设,通过双分支架构,即全局关联测度(Globally Contextual Measure, GCM)和局部关联测度(Locally Contextual Measure, LCM),分别建模全局与局部关联性。GCM 分支利用空间敏感卷积捕获全局位置依赖,LCM 分支通过固定卷积核提取邻近区域关系,最终融合两者特征生成身份标识。CM 在复杂场景下表现优异,但仍存在以下问题。

1)全局特征处理的冗余性。GCM 分支对全图信息平等处理,容易将一些遮挡或噪声信息混入特征表示,干扰关键区分性特征的学习。当无关特征占据较大比例时,关键的区分性信息被大量无关特征所稀释,模型可能难以有效提取出用于识别的显著特征,以至于在区分不同虹膜类别时的敏感性降低。

2)多尺度特征捕捉能力不足。虹膜图像中存在不同尺度的纹理和微结构,但现有方法缺乏专门捕捉这些多尺度特征的机制。

3)特征融合的简单化。当前 CM 方法通过求和运算和线性投影融合 GCM 和 LCM 的特征,简单的求和方法未能充分挖掘全局与局部特征之间的互补性和相互作用,

限制了特征表达能力。

基于上述问题,本文在 CM 双分支基础上做了如下改进:

1)在 GCM 前端引入基于通道注意力机制的 SCE 模块(Squeeze-and-Convolutional Excitation Module)。SCE 模块利用自适应平均池化和逐点乘法操作,对输入特征图进行动态调整和通道重标定。SCE 通过抑制低响应通道,使后续 GCM 处理聚焦于高判别性区域,避免了冗余计算,有效提升了计算性能。

2)在 GCM 后端嵌入 EMA<sup>[17]</sup>(Efficient Multi-Scale Attention Module)模块。EMA 模块通过并行卷积结构同时处理和整合来自不同尺度的特征图,有效捕捉短距离和长距离依赖关系,提高了多尺度特征的代表能力。通过跨空间的特征融合,EMA 模块在 GCM 输出的全局特征的基础上,进一步捕获跨维度的交互,丰富了模型对不同感受野范围内特征的感知能力。

3)引入了基于注意力的特征融合机制(Attention based Feature Fusion, AFF)<sup>[18]</sup>代替求和运算。AFF 通过学习不同特征之间的相关性,动态地更新特征融合的权重,实现了对全局和局部关联测度的优化融合。这种融合策略不仅保留了 GCM 分支对全局结构的敏感性,也融合了 LCM 分支对局部细节的捕捉能力,进一步提升了模型对复杂场景下虹膜特征的识别精度。

本文的主要贡献如下:

1)提出了一种改进的虹膜识别框架——自适应关联学习网络(Adaptive Contextual Learning Network, ACLNet),用于虹膜特征提取。自适应关联学习网络在保留 CM 描述全局和局部关联测度框架的同时,通过引入注意力机制和特征融合策略,显著增强了对虹膜图像中微结构特征的表达能力。

2)提出了基于通道注意力机制的 SCE 模块(Squeeze-and-Convolutional Excitation Module)。该模块利用通道间的依赖关系自适应地调整权重,优化了特征提取过程,使得网络能够更有效地捕捉和强调对虹膜识别有贡献的显著特征。

3)在 3 个公开虹膜数据集上进行了跨库实验。实验结果表明,自适应关联学习网络在 3 个数据集上的表现优于现有的虹膜识别方法,验证了所提出框架和 SCE 模块在提高虹膜识别精度方面的有效性。

## 2 相关工作

### 2.1 虹膜识别

早期研究中,Daugman 提出的 Iris Code<sup>[2]</sup>通过 Gabor 滤波器提取虹膜相位特征并量化为 2 048 位编码,奠定了虹膜编码的理论基础。Sun 等<sup>[5]</sup>提出了 Ordinal code,将定序测量应用到虹膜特征表示中用于描述定性关系,但其量化过程可能丢失部分图像细节信息。

不同于传统虹膜识别,使用卷积神经网络可以自动学习输入图像的特征表示,无需依赖手工设计的滤波器。UniNet<sup>[11]</sup>通过多尺度特征融合策略构建集成特征图,有效替代了传统手工滤波器。Maxout CNN<sup>[12]</sup>采用 Maxout 激活函数生成紧凑特征表示,在保证识别精度的同时降低了计算

复杂度。DeepIrisNet2<sup>[19]</sup>直接处理未归一化虹膜图像,通过深度特征学习有效应对光照、尺度及仿射变换的干扰。Jia等<sup>[20]</sup>创新性地引入球 Haar 小波基,实现了虹膜曲面的多尺度分解与重构。DGR(Dynamic Graph Representation)<sup>[15]</sup>框架通过结合 CNN 和图形模型,动态地构建和匹配特征图来适应遮挡情况。ISFR(Iris Spatial Feature Reconstruction)<sup>[21]</sup>基于全卷积网络提取多尺度空间特征,结合字典学习机制重建受损区域特征。CM<sup>[16]</sup>通过全局和局部关联分支(GCM 和 LCM),通过全局-局部关联分支建模虹膜微结构,并引入扰动瓶颈减少特征冗余。

## 2.2 注意力机制

注意力机制模拟人类视觉选择性注意特性,已成为提升深度神经网络性能的关键技术。根据作用域差异,现有研究主要聚焦 5 类注意力机制<sup>[22]</sup>:1)全局注意力,强化关键输入区域;2)空间注意力,定位重要空间位置;3)通道注意力,筛选有效特征通道;4)自注意力,建模长程依赖关系;5)独立注意力,替代传统卷积操作。

在计算机视觉领域中,通道注意力机制通过特征通道的权重重标定显著提升特征表达能力。SE-Net<sup>[23]</sup>(Squeeze and Excitation Network)首创“压缩-激励”框架,通过全局平均池化生成通道描述符并建立通道间相关性。ECA-Net<sup>[24]</sup>改进了

SE 的通道交互方式,采用 1D 卷积保持通道直接对应关系。A-PBS(Attention Based Pixel-wise Binary Supervision)<sup>[25]</sup>通过空间特征加权引导网络聚焦判别性区域。CBAM<sup>[26]</sup>(Convolutional Block Attention Module)则首次实现空间与通道注意力的协同优化。Luo等<sup>[27]</sup>提出的联合注意力网络通过空间-通道双注意力机制实现虹膜与周周特征的动态融合。DualSANet<sup>[28]</sup>构建编码器-解码器架构下的双空间注意力框架,其提出的 SAFFM 模块(Spatial Attention Feature Fusion Module)通过多级特征图的空间权重细化,使得 DualSANet 能够更加灵活地处理不同层级的特征信息,有效提升复杂虹膜纹理的表征能力。

## 3 ACLNet 模型

### 3.1 整体结构

本文提出了一种改进的自适应关联学习网络架构 ACLNet(见图 1),其保留了图块嵌入头和 CM 原有的双分支结构和识别头(VIB\_head),在全局关联测度分支 GCM 的头部和尾部分别添加了 SCE 模块和 EMA 模块,输入 GCM 的特征在进行标准化之后通过 SCE 进行加权,经 EMA 模块进行多尺度特征处理后输出,通过基于注意力机制的特征融合模块和识别头将两个分支的特征融合。

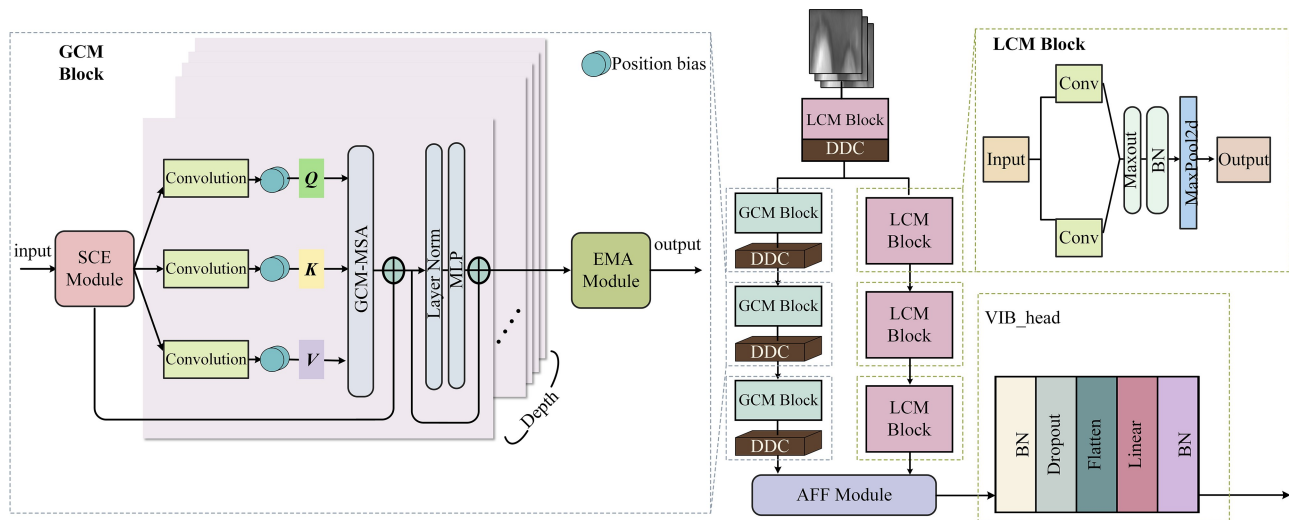


图 1 自适应关联学习网络(ACLNet)的总体框架

Fig. 1 Overall framework of adaptive contextual learning network(ACLNet)

图块嵌入头包括 LCM 模块和密集下采样卷积层(Dense Downsampling Convolutional Layer, DDC)两部分。DDC 主要对特征图进行下采样,在保留更多的特征信息的同时将特征图的空间分辨率降低。图块嵌入头可以确保后续网络处理的是空间分辨率更小但特征维数更高的特征图。从图块嵌入头输出的特征图,分别被馈送到 GCM 和 LCM 这两个并行分支中。GCM 分支由 GCM 模块和 DDC 交替堆叠进行逐层的特征转换。LCM 分支由 LCM 模块构成,以实现局部关联性聚合。

为了有效地融合这两个分支学习的特征,本文提出的自适应关联学习网络中将文献<sup>[16]</sup>中的求和运算替换成基于注意力机制的特征融合模块 AFF,由 AFF 和线性投影的识别头组合共同实现特征融合。

### 3.2 全局关联测度模块

#### 3.2.1 通道注意力模块

通道注意力机制通过计算输入数据中各个部分之间的相关性,赋予不同特征不同的权重,从而增强模型对重要特征的专注能力。SE、CBAM 等注意力机制已被广泛应用于卷积网络中的分类任务,证明了其在提升模型性能方面的有效性。

受到 SE 模块挤压-激励操作的启发,本文提出了一种保留空间特征的通道注意力模块 SCE(Squeeze-and-Convolutional Excitation Module),如图 2 所示。

SE 模块采用通道注意力机制,使用两个全连接层和 Sigmoid 函数来学习每个通道的重要性,进而根据这些权重来自适应地重新标定特征通道,强调有用的特征并抑制不重要的特征。但是 SE 模块主要依赖于全连接层来处理池化后的

特征数据,这在计算效率上存在一定的瓶颈。卷积操作具有出色的跨通道特征提取能力,因此 SCE 模块用  $1 \times 1$  的二维卷积层代替原有的全连接层生成通道注意力权重,从而提高计算效率并保留空间信息,使得它能够与卷积神经网络中的其他层更好地协同工作。

对于输入特征图  $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$ ,首先通过挤压(Squeeze)操作进行全局平均池化,将空间维度  $H \times W$  压缩为每个通道的全局描述符  $\mathbf{z}_c$ 。该描述符捕捉了整个特征图的平均信息,其计算式如下:

$$\mathbf{z}_c = \frac{1}{H \times W} \sum_{n=1}^N \sum_{d=1}^D \mathbf{u}_c(i, j) \quad (1)$$

其中,  $\mathbf{u}_c(i, j)$  是特征图中第  $c$  个通道的第  $(i, j)$  位置的值。在 SCE 模块,通过两个  $1 \times 1$  卷积层来处理全局平均池化的结果。卷积操作的计算式为:

$$\mathbf{X}'_{b, c_{out}, h, w} = \sum_{c_{in}=1}^{C_{in}} \mathbf{W}_{1, 1, c_{in}, c_{out}} \cdot \mathbf{X}_{b, c_{in}, h, w} \quad (2)$$

其中,  $\mathbf{W}_{1, 1, c_{in}, c_{out}}$  是卷积核的权重,  $c_{in}$  和  $c_{out}$  分别表示输入通道和输出通道的数量。卷积操作仅改变通道数,而不改变空间维度,具有良好的计算效率。

在特征压缩后,通过激励(Excitation)操作对  $\mathbf{z}$  进行非线性激活,进一步增强模型对重要特征的敏感性。首先通过一个  $1 \times 1$  卷积进行特征压缩,并应用 ReLU 激活函数  $\delta$ ; 然后通过另一个  $1 \times 1$  卷积恢复特征,并应用 Sigmoid 激活函数  $\sigma$  生成通道权重  $s$ ,其表达式如下:

$$s = \sigma(\mathbf{W}_2 \delta(\mathbf{W}_1 \mathbf{z})) \quad (3)$$

其中,  $\mathbf{W}_1 \in \mathbb{R}^{\frac{C}{r} \times C}$ ,  $\mathbf{W}_2 \in \mathbb{R}^{C \times \frac{C}{r}}$ 。Sigmoid 函数  $\sigma$  作为门控机制,在此过程中自适应地生成每个通道的权重,决定了每个通道对最终特征图的贡献大小。最终,通过将生成的调制权重  $s$  扩展到与输入特征图  $\mathbf{X}$  相同的维度,并进行逐通道乘法,得到重标定后的特征图  $\tilde{\mathbf{x}}$ :

$$\tilde{\mathbf{x}} = F_{scale}(\mathbf{u}_c, s_c) = s_c \cdot \mathbf{u}_c \quad (4)$$

其中,  $F_{scale}(\mathbf{u}_c, s_c)$  表示对每个通道  $\mathbf{u}_c$  和相应的门控权重  $s_c$  进行逐通道乘法。通过这种方式, SCE 模块能够动态调整每个通道的响应,使得模型能够自适应地重标定特征图的通道,以提升对有用特征的敏感性。




图 2 SCE 模块结构图

Fig. 2 Framework of SCE module

### 3.2.2 Transformer

GCM 模块利用强大的视觉 Transformer<sup>[29]</sup> 来实现全局关联测度的建模,考虑到微结构在虹膜纹理中的随机分布,将 Transformer 的线性投影替换成卷积投影来生成自注意力输入(即 query, key 和 value)。假设输入特征图  $\mathbf{X} \in \mathbb{R}^{H \times W \times D}$  的空间分辨率为  $H \times W$ , GCM 模块通过式(5)生成注意力输入 query(Q), key(K) 和 value(V):

$$\mathbf{Q} = \phi_Q(\mathbf{X}), \mathbf{K} = \phi_K(\mathbf{X}), \mathbf{V} = \phi_V(\mathbf{X}) \quad (5)$$

其中,  $\phi_Q, \phi_K, \phi_V$  对  $\mathbf{X}$  进行卷积投影和序列化标记。卷积投影能够捕捉特征图中的局部空间信息,相较于传统线性投影,它不再忽视像素间的空间位置关系,使得生成的注意力输入更贴合虹膜图像复杂的纹理特征。序列化标记则将卷积后的结果转化为适合后续计算处理的格式,为自注意力机制的高效运行奠定基础。

其次, GCM 采用绝对位置偏差来描述空间位置,避免了 Transformer 中使用相对位置偏差造成的视野受限。具体操作如下,首先学习嵌入矩阵  $\mathbf{W} = [\omega_1, \omega_2, \dots, \omega_{2HW}] \in \mathbb{R}^{2HW}$  存储所有偏差情况的位置相关性数值,再根据区域位置从  $\mathbf{W}$  中采样生成绝对位置偏差:

$$\mathbf{B}_{ij} = \mathbf{W}^{HW + (h_i - h_j) - (\omega_i - \omega_j)} \quad (6)$$

其中,  $(h_i, \omega_i)$  和  $(h_j, \omega_j)$  分别表示第  $i$  个和第  $j$  个区域的空间位置。在 GCM 模块中,自注意力模块(GCM-MSA)的计算过程可以表示为:

$$\begin{aligned} \text{GCM-MSA}(\mathbf{X}) &= \text{Attention}(\phi_Q(\mathbf{X}), \phi_K(\mathbf{X}), \phi_V(\mathbf{X})) \\ &= \text{Softmax}\left(\frac{\phi_Q(\mathbf{X})\phi_K(\mathbf{X})^T}{\sqrt{D}} + \mathbf{B}\right)\phi_V(\mathbf{X}) \end{aligned} \quad (7)$$

GCM 模块的计算过程可以表示为:

$$\begin{aligned} \hat{\mathbf{X}}^l &= \text{GCM-MSA}(\text{LN}(\mathbf{X}^{l-1})) + \mathbf{X}^{l-1} \\ \mathbf{X}^l &= \text{MLP}(\text{LN}(\hat{\mathbf{X}}^l)) + \hat{\mathbf{X}}^l \end{aligned} \quad (8)$$

其中,  $\hat{\mathbf{X}}^l$  和  $\mathbf{X}^l$  分别表示第  $l$  层的注意力模块和多层感知器(MLP)模块的输出, LN 代表层归一化。此外 GCM 分支在每个 GCM 模块后插入了一个下采样模块(DDC),以通过降低特征图分辨率,减少需要聚合的虹膜区域数量,降低 GCM 模块基于密集采样构建全局上下文带来的计算成本。

### 3.2.3 EMA 模块

在 EMA<sup>[30]</sup> 的基础上进行扩展,引入了多尺度特征提取和跨空间学习,通过在不同尺度上捕捉和整合特征,增强了模型对虹膜图像中多尺度信息的表达能力。如图 3 所示, EMA 将输入特征图  $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$  在通道维度上划分为  $G$  个子特征,并将其分成多个子特征组,以学习不同的语义。为了避免过深的网络结构并建立大的局部感受野来收集多尺度信息, EMA 采用并行子结构:  $1 \times 1$  卷积分支和  $3 \times 3$  卷积分支。将  $1 \times 1$  卷积分支分别沿宽高两个维度池化后拼接,共享相同的  $1 \times 1$  卷积后沿两个空间方向分解为两个特征向量,分别用 Sigmoid 函数来拟合。拟合后的特征向量用乘法聚合以实现并行路线间的特征交互。而在  $3 \times 3$  分支中则用  $3 \times 3$  卷积来捕捉多尺度特征表示,最后两个分支全局特征通过矩阵乘法和加权求和融合。

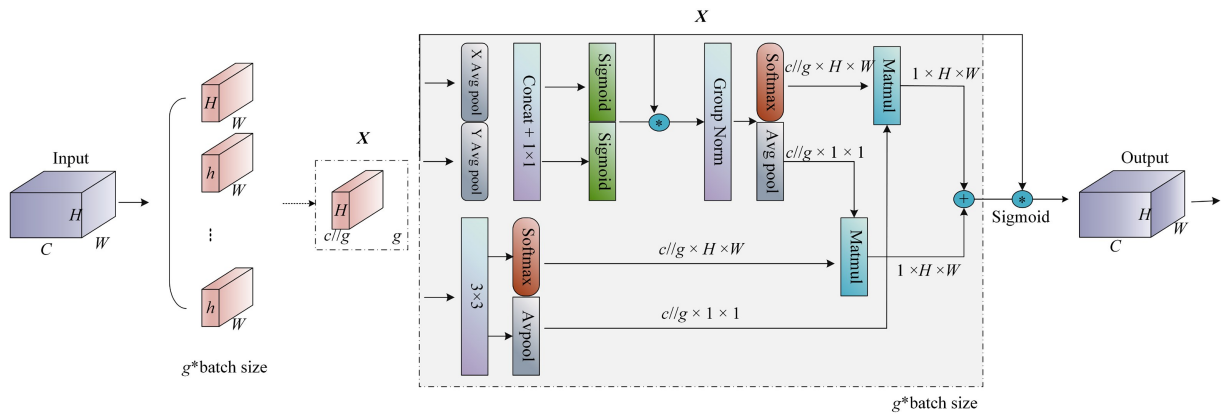


图3 EMA 模块的结构

Fig. 3 Framework of EMA

其中  $1 \times 1$  卷积分支有效地捕捉到了短距离的跨通道依赖性,而  $3 \times 3$  卷积分支则扩展了感受野,能捕捉更大范围内的多尺度特征。通过联合激活机制融合策略,EMA 模块将不同尺度的特征图进行有效整合,以获得更全面的虹膜表征。

### 3.3 局部关联测度模块

LCM 专注于学习局部关联测度,能够捕捉邻近区域的细节信息,更好地感知局部纹理细节,弥补了 GCM 对局部细节不够敏感的不足。作为 LCM 分支的基本聚合模块,LCM 模块由 MFM(Max-Feature-Map)<sup>[12]</sup> 和一个最大池化层构成。其中 MFM 通过将特征图在通道维度上拆分为两个部分,分别进行逐元素的最大值操作,从而保留每个位置上最显著的特征,突出了局部信息的识别。

### 3.4 密集下采样卷积层

DDC 包含像素打乱层<sup>[31-32]</sup>、批归一化层、卷积层和 ReLU 层,旨在降低特征图的空间分辨率。相较于传统的最大池化层,DDC 模块通过综合不同操作来改变分辨率,在特征信息的保持和处理上表现得更为灵活。

### 3.5 基于注意力机制的特征融合模块

为了最大程度地挖掘来自不同分支的互补性,本文采用了 TSCNN(two-stream CNN)<sup>[33]</sup> 中基于注意力机制的特征融合模块 AFF(Attention Based Feature Fusion Module) 来对 GCM 和 LCM 分支输出的特征进行加权融合,以获取特征间的复杂关系和相互作用,如图 4 所示。

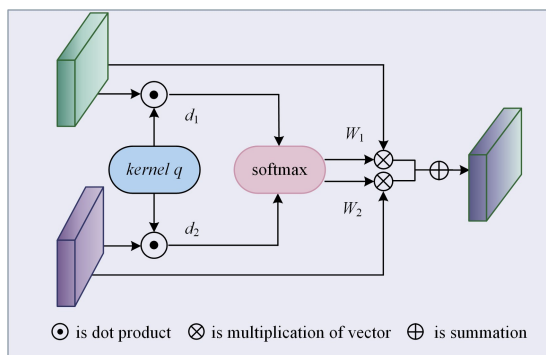


图4 AFF 模块的结构

Fig. 4 Framework of AFF

AFF 中的关键是根据学习到的权重  $\{\omega_i\}_{i=1}^N$  对输入的

特征向量  $\{f_i\}_{i=1}^N$  加权,生成两分支的聚合特征  $v$ ,即:

$$v = \sum_{i=1}^N \omega_i f_i \quad (9)$$

$$\omega_i = \frac{e^{d_i}}{\sum_j e^{d_j}} \quad (10)$$

$$d_i = q^T f_i \quad (11)$$

其中,  $d_i$  对  $\omega_i$  的传递由 Softmax 完成,在这里定义了可学习的注意力核  $q$ ,用来过滤特征向量,计算表示特征重要性的值  $d$ 。参数  $q$  的值在训练中通过反向传播和随机梯度下降不断被优化,以适应特定任务的特征融合需求,使得模型能够更好地学习到特征之间的有效关系。此外,聚合特征  $v$  在经过 AFF 模块后,会进一步通过识别头进行线性投影,以完成最终的分类或识别任务。

### 3.6 目标函数

为了显著提升虹膜识别任务中特征表示的区分度并提高分类性能,本文采用了 ArcFace<sup>[34]</sup> 损失函数。ArcFace 通过引入角度间隔,显式提升同类样本的相似度并降低不同样本之间的相似度,从而增强分类器的判别能力。其目标函数的定义如下:

$$\mathcal{L}_{\text{arc}}(z) = -\frac{1}{N} \sum_{n=1}^N \log \frac{e^{g(\cos(\theta_n + m))}}{e^{g(\cos(\theta_n + m))} + \sum_{c=1, c \neq y_n}^C e^{g \cos \theta_c}} \quad (12)$$

其中,  $\cos \theta_c = \frac{W_c^T z_n}{\|W_c\| \|z_n\|}$  表示第  $n$  个样本的特征向量  $z_n$  与类别  $c$  对应的权重向量  $W_c$  之间的余弦距离;  $g$  是特征的缩放因子,用于增强角度间隔的效果;  $m$  是角度间隔的罚项,用于增加同类样本之间的角度差距。根据文献<sup>[34]</sup>,实验中将  $g$  和  $m$  分别设置为 64 和 0.5。

## 4 实验

### 4.1 数据集

为了提升模型的泛化能力并有效减少过拟合,本文在大规模多样化的虹膜数据集上进行了训练。训练集包含来自 3684 类虹膜的共 66955 张图像,这些图像来源于多个数据集,包括 Bath(University of Bath Iris Image Database)、CA-SIA-IrisV4(Lamp, Thousand, Interval) 和 CASIA-CSIR2015(The ICB Competition on Cross Sensor Iris Recognition)。这些数据集涵盖了多样化的虹膜图像样本,有助于模型在训练

阶段学习到广泛的特征分布,从而增强其鲁棒性,减少过拟合现象,并提升其在目标任务中的性能表现。

为了验证所提方法的有效性,本文在 3 个虹膜数据集上进行跨库测试,以评估模型的性能。所用测试数据集是由中国科学院自动化研究所(CASIA)公开发布的 CASIA-IrisV4-Distance, CASIA-Iris-M1-S2 和 CASIA-Iris-M1-S3。3 个数据集的示例图片如图 5 所示。




图 5 CASIA-IrisV4-Distance, CASIA-Iris-M1-S2 和 CASIA-Iris-M1-S3 数据集的示例图像

Fig. 5 Example images of the CASIA-IrisV4-Distance, CASIA-Iris-M1-S2 and CASIA-Iris-M1-S3 dataset

1) CASIA-IrisV4-Distance。该数据集由 CASIA 使用自主研发的设备在 3m 外采集,旨在评估模型在远距离下的识别能力。本文的实验协议与文献[16]相同,所用测试集包含 142 个类别的 1500 张虹膜图像。

2) CASIA-Iris-M1-S2。该数据集由连接至手机的 CASIA NIR mobile module V2 在每种距离下采集 10 张图像得到,采集距离分别为 20 cm, 25 cm 和 30 cm。这种多距离采集的设置可以模拟移动设备的实际应用情况,并用来研究识别系统受距离影响发生的性能变化。本文的实验协议与文献[16]相同,所用测试集包含 200 个类别的 6000 张虹膜图像。

3) CASIA-Iris-M1-S3。该数据集由带有近红外(NIR)虹膜扫描技术的国产手机采集,适用于较大规模移动端虹膜识别研究,旨在测试模型在光照不均、镜面反射以及佩戴眼镜时等遮挡条件下的虹膜识别性能。本文的实验协议与文献[12]相同,所用测试集包含 360 个类别的 3600 张虹膜图像。

在本文的实验中,不使用测试数据库中的训练集对预模型参数进行训练和调整,所有实验均为跨库实验。在这种情况下,测试数据集中的类别是训练数据集中从未见过的类别。这种设置更接近真实场景,其中训练数据和测试数据可能来源于不同的数据库或具有不同的特征。跨数据库识别要求模型具有良好的泛化能力,不仅在训练数据上表现良好,还需要对新的、未知的数据具有较强的适应性。因此,这种方法使得评估结果更加可靠,在实际应用中具有重要意义,但也增加了模型评估的难度,具有一定的挑战性。

## 4.2 评价指标

在本实验中计算每种方法生成的特征向量对之间的余弦相似度,并将其作为匹配分数计算几种关键指标,即 FMR 分别为  $10^{-3}$ ,  $10^{-5}$  时的 FNMR, EER, DET 曲线,以评估虹膜识别方法的性能。当 FMR 为  $10^{-5}$  时,表示将负样本误判为正样本的比例为 1/100 000。在这种情况下, FNMR 通常会较高,因为系统在控制错误匹配方面表现优异,但可能导致错误拒绝的比例增加。因此, FNMR@FMR =  $10^{-5}$  被认为是评估

模型性能最具挑战性的指标。

### 1) FMR(False Match Rate, 错误匹配率)

FMR 是在识别负样本的情况下,系统将错误样本误判为正确匹配的比例。FMR 用于衡量系统在识别错误时的错误匹配率。较低的 FMR 表明系统能够更准确地避免将错误样本误判为匹配。

### 2) FNMR(False Non-Match Rate, 错误不匹配率)

FNMR 是在识别正样本的情况下,系统错误判定为不匹配的比例。FNMR 用于评估系统在正确样本情况下的错误不匹配率。较低的 FNMR 表示系统能够更准确地识别匹配样本。

### 3) EER(Equal Error Rate, 等错误率)

EER 是生物识别系统中一个重要的性能评估指标,指 FMR 和 FNMR 两条曲线的交点。通常 EER 值越低,表明系统在该特定阈值下的平衡性和性能越好。

### 4) DET 曲线(Detection Error Tradeoff)

DET 曲线展示了 FNMR 和 FMR 随着阈值变化时的变化情况,其横轴为 FMR,纵轴为 FNMR。DET 曲线的弧线越靠近左下角,说明分类的性能越好。该曲线有助于理解系统在不同阈值下的性能平衡,以及如何在错误匹配和错误不匹配之间进行权衡。

## 4.3 训练设置

本文提出的自适应关联学习网络基于 PyTorch 构建,实验在 14 vCPU Intel(R) Xeon(R) Gold 6348 CPU @ 2.60 GHz、NVIDIA A800 80GB PCIe GPU 上进行。在训练阶段,使用分辨率为  $128 \times 128$  的归一化虹膜图像作为输入,设置了 100 次迭代,批量大小为 200,动量为 0.9,权重衰减为 0.0005。使用 SGD 优化器调整学习率,初始学习率为 0.001,并在第 30, 50 和 70 次迭代时分别乘以衰减因子 0.1。此外,为了与文献[2]、文献[5]、文献[11]、文献[12]和文献[16]的研究结果进行公平对比,对比实验均沿用了与文献[16]相同的参数设置。

## 4.4 性能比较

本文在 3 个数据集(CASIA-IrisV4-Distance, CASIA-Iris-M1-S2 和 CASIA-Iris-M1-S3)上开展实验,系统分析了所提方法在不同场景下的表现。表 1 列出了跨库实验的结果,其中不同方法在各数据集上的性能以百分比形式呈现(表中最优结果用加粗字体标注,次优结果用下划线标注)。表 1 中的  $10^{-1}$  和  $10^{-3}$  分别表示 FMR 为  $10^{-3}$  和  $10^{-5}$  时的 FNMR。此外,为进一步直观比较基准算法与本文方法在处理测试样本时的表现差异,图 6(a)~图 6(c)和图 7 分别给出了 DET 曲线及余弦相似度分布图,清晰展示了算法性能的具体对比。

跨库实验结果如表 1 以及图 6(a)~图 6(c)所示。改进后的网络架构在多个虹膜数据集上的识别精度均优于现有技术。在识别难度较大的远距离数据集 CASIA-IrisV4-Distance 上,本文算法的 EER, FNMR@FMR =  $10^{-3}$  和 FNMR@FMR =  $10^{-5}$  指标分别为 1.42%, 4.46% 和 13.23%,较现有最优基线方法 CM(1.67%, 4.93%, 14.97%)分别降低了一 14.97%, 9.53% 和 11.62%。在 CASIA-Iris-M1-S2 数据集上,本文算法的 EER, FNMR@FMR =  $10^{-3}$  和 FNMR@FMR =  $10^{-5}$

指标分别为 0.41%,0.73%和 2.64%,较现有最优基线方法 CM(0.49%,0.88%,3.26%)分别降低了 19.51%,16.33%和 19.02%。在 CASIA-Iris-M1-S3 数据集上,本文算法的 EER,FNMR@FMR=10<sup>-3</sup>和 FNMR@FMR=10<sup>-5</sup>指标分别为 1.35%,3.04%和 8.10%,较现有最优基线方法 CM(1.48%,3.37%,10.02%)分别降低了 8.78%,9.79%和 -19.16%。实验结果表明,本文对 CM 的改进在提升模型性能方面取得了较好的效果。

表 1 不同虹膜识别方法在 3 个数据集上的跨库实验结果对比

Table 1 Comparison of results for different iris recognition methods under cross-database experimental settings on three datasets

Methods	CASIA-IrisV4-Distance			CASIA-Iris-M1-S2			CASIA-Iris-M1-S3		
	EER	10 <sup>-1</sup>	10 <sup>-3</sup>	EER	10 <sup>-1</sup>	10 <sup>-3</sup>	EER	10 <sup>-1</sup>	10 <sup>-3</sup>
IrisCode	12.79	57.38	73.61	3.93	23.42	46.56	—	—	—
OM	18.97	62.57	80.27	4.27	20.69	40.27	12.74	60.06	81.38
UniNet	3.76	17.55	38.08	1.86	5.50	12.15	4.91	16.53	42.09
MaxoutCNN	3.79	16.24	33.54	1.78	5.25	12.94	5.34	20.56	37.17
CM	1.67	4.93	14.97	0.49	0.88	3.26	1.48	3.37	10.02
Ours	<b>1.42</b>	<b>4.46</b>	<b>13.23</b>	<b>0.41</b>	<b>0.73</b>	<b>2.64</b>	<b>1.35</b>	<b>3.04</b>	<b>8.10</b>

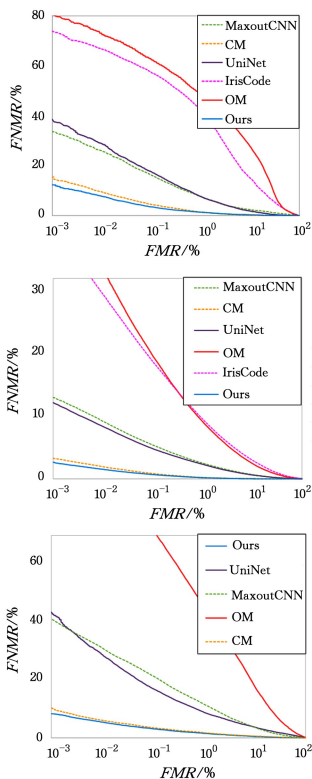


图 6 不同虹膜识别方法在 3 个数据集上的跨库实验 DET 曲线

Fig. 6 DET curves of different iris recognition methods under the cross-database experimental setting on three datasets

图 7 以 CASIA-Iris-M1-S2 为例给出了本文算法的余弦相似度分布情况。余弦距离计算的是两个特征向量之间夹角的余弦值,值的范围为 -1 到 1。余弦距离越接近 1 说明特征向量夹角越小,相似度越高,表示这些样本在特征空间中非常接近。图 7 中,蓝色线条代表类内分布,紫色线条代表类间分布,可以看出,本文算法能够更有效地区分类内样本和类间样本。




图 7 余弦相似度分布图(电子版为彩图)

Fig. 7 Cosine similarity distribution plot

#### 4.5 消融实验

为了深入评估 ACLNet 中加入的各个基于注意力机制的模块对整体性能的贡献,本文在 CASIA-Iris-M1-S3 数据集上进行了一系列的消融实验以量化 SCE 模块、EMA 模块以及特征融合模块(AFF)对模型性能的影响。本节通过选取以下 4 种消融行为中每种方法的最佳模型进行实验:1)去掉 SCE 模块(w/o S);2)去掉 EMA 模块(w/o E);3)使用元素级加和运算代替特征融合模块(w/o AFF(+));4)使用元素级乘积代替特征融合模块(w/o AFF(\*))。

表 2 列出了消融实验的结果,可以看出,带有 SCE 模块、EMA 模块以及特征融合模块(AFF)的 ACLNet 优于所有基线。显然,与 ACLNet 相比,去掉部分注意力机制模块的识别模型在识别性能上明显下降。

表 2 在 CASIA-Iris-M1-S3 数据集上的消融实验结果

Table 2 Ablation experiments results on CASIA-Iris-M1-S3 dataset

	FNMR@FMR	EER	10 <sup>-1</sup>	10 <sup>-3</sup>
Full	<b>1.35</b>	<b>3.04</b>	<b>8.10</b>	
w/oS	1.64	3.73	11.21	
w/oE	1.86	4.62	13.52	
w/oAFF(+)	1.43	3.14	9.20	
w/oAFF(*)	1.65	4.18	10.54	

1)SCE 模块。根据表 2 中的结果可知,去除 SCE 模块(w/o S)显著降低了识别性能。这一下降主要源于全局信息的丧失和通道间交互的缺失,从而影响了特征的表达能力。SCE 模块通过自注意力机制增强了模型对关键特征的关注,移除后导致模型在特征选择上的能力下降。具体表现为, FNMR@FMR=10<sup>-5</sup>显著上升,EER 也有明显增加。相比完整模型,EER,FNMR@FMR=10<sup>-3</sup>和 FNMR@FMR=10<sup>-5</sup>分别上升了 21.48%,22.7%,38.4%。

2)EMA 模块。EMA 模块的并行卷积结构能够有效捕捉多尺度特征信息,而联合激活机制帮助模型区分重要和不重要的特征。移除 EMA 模块(w/o E)可能导致模型特征选择能力下降,且丧失了对多尺度信息的有效整合,导致性能显著下降,所有指标均出现大幅度下降。相比于完整模型,EER,FNMR@FMR=10<sup>-3</sup>和 FNMR@FMR=10<sup>-5</sup>分别上升了 37.78%,51.97%和 66.91%。

3)AFF 机制。在提出的 ACLNet 模型中,注意力特征融合模块被替换为两种常用的特征融合方法——元素级加和与元素级乘积。表 2 列出了 3 种方法在不同指标上的比较结果。使用元素级加和(w/o AFF(+))的性能在各项指标上

均不如使用 AFF, 在 CASIA-Iris-M1-S3 上, 使 AFF 的 EER 上升了 5.93%, FNMR@FMR=10<sup>-3</sup> 上升了 3.29%, FNMR@FMR=10<sup>-5</sup> 上升了 13.58%。使用元素级乘积运算(w/o AFF(\*))在 CASIA-Iris-M1-S3 数据集上的表现与 AFF 差距更大, 具体表现为使用 AFF 的 EER, FNMR@FMR=10<sup>-3</sup> 和 FNMR@FMR=10<sup>-5</sup> 分别上升了 22.2%, 35.7% 和 30.12%。AFF 通过自注意力机制对来自不同分支的特征进行加权融合, 使得特征融合过程更加精细和高效。与传统的特征融合方法(如元素级加和与乘积)相比, AFF 能够更有效地处理特征间的复杂关系。去除 AFF 机制后, 模型无法有效挖掘特征间的复杂关系与互补性, 导致特征融合能力下降, 从而显著降低了识别性能。

**结束语** 本文针对现有虹膜识别方法中的局限性, 提出了一种基于虹膜纹理感知的自适应关联学习方法, 通过注意力机制和特征融合策略, 提升了虹膜识别系统的性能。在保留 CM 双分支结构的基础上, 引入了自注意力模块(SCE)和 EMA 模块, 并通过基于注意力的特征融合机制(AFF)对全局和局部特征进行融合。SCE 自适应地调整输入特征图, 增强了对重要信息的关注, 同时抑制了不相关特征的干扰。EMA 有效地融合了不同尺度的特征, 提高了对虹膜微结构的敏感度。基于注意力的特征融合机制则通过动态调整特征融合权重, 优化了全局和局部特征的结合, 提升了模型对复杂场景下虹膜特征的识别能力。改进后的网络架构在 CASIA-IrisV4-Distance, CASIA-Iris-M1-S2 和 CASIA-Iris-M1-S3 这 3 个数据集上的等错误率(EER)分别为 1.42%, 0.41% 和 1.35%。实验结果表明, ACLNet 网络在跨库场景下展现出了较好的识别精度与泛化能力。

本文方法提升了虹膜识别的准确性和可靠性, 未来的研究可以进一步探索自注意力机制在特征提取任务中的应用, 以不断提高识别系统的性能和适用范围。

## 参考文献

- [1] HE Z, TAN T, SUN Z, et al. Toward accurate and fast iris segmentation for iris biometrics[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 31(9): 1670-1684.
- [2] DAUGMAN J G. High confidence visual recognition of persons by a test of statistical independence[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 15(11): 1148-1161.
- [3] DAUGMAN J. How iris recognition works[M]//The essential guide to image processing. Academic Press, 2009: 715-739.
- [4] MA L, TAN T, WANG Y, et al. Efficient iris recognition by characterizing key local variations[J]. IEEE Transactions on Image Processing, 2004, 13(6): 739-750.
- [5] SUN Z, TAN T. Ordinal measures for iris recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 31(12): 2211-2226.
- [6] PROENÇA H, NEVES J C. IRINA: Iris recognition(even) in inaccurately segmented data[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 538-547.
- [7] LIU N, LIU J, SUN Z, et al. A code-level approach to heterogeneous iris recognition[J]. IEEE Transactions on Information Forensics and Security, 2017, 12(10): 2373-2386.
- [8] NALLA P R, KUMAR A. Toward more accurate iris recognition using cross-spectral matching[J]. IEEE Transactions on Image Processing, 2016, 26(1): 208-221.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [10] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. Neural Networks, 2015, 61: 85-117.
- [11] ZHAO Z, KUMAR A. Towards more accurate iris recognition using deeply learned spatially corresponding features[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017: 3809-3818.
- [12] ZHANG Q, LI H, SUN Z, et al. Deep feature fusion for iris and periocular biometrics on mobile devices[J]. IEEE Transactions on Information Forensics and Security, 2018, 13(11): 2897-2912.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv: 1409.1556, 2014.
- [15] REN M, WANG Y, SUN Z, et al. Dynamic graph representation for occlusion handling in biometrics[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2020: 11940-11947.
- [16] WEI J, WANG Y, HUANG H, et al. Contextual measures for iris recognition[J]. IEEE Transactions on Information Forensics and Security, 2022, 18: 57-70.
- [17] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP 2023). IEEE, 2023: 1-5.
- [18] CHEN H, HU G, LEI Z, et al. Attention-based two-stream convolutional networks for face spoofing detection[J]. IEEE Transactions on Information Forensics and Security, 2019, 15: 578-593.
- [19] GANGWAR A, JOSHI A, JOSHI P, et al. Deepirisnet2: Learning deep-iris codes from scratch for segmentation-robust visible wavelength and near infrared iris recognition[J]. arXiv: 1902.05390, 2019.
- [20] JIA B, FENG X X, LI J, et al. Pilot Iris Recognition Based on Spherical Haar Wavelet and Convolutional Neural Network[J]. Journal of Electronics & Information Technology, 2021, 43(4): 939-947.
- [21] YAN Z, HE L, WANG Y, et al. Flexible iris matching based on spatial feature reconstruction[J]. IEEE Transactions on Biometrics, Behavior, and Identity Science, (Early Access).
- [22] PECORARO R, BASILE V, BONO V. Local multi-head channel self-attention for facial expression recognition[J]. Information, 2022, 13(9): 419.
- [23] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//

- Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [24] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:11534-11542.
- [25] FANG M, DAMER N, BOUTROS F, et al. Iris presentation attack detection by attention-based and deep pixel-wise binary supervision network [C] // 2021 IEEE International Joint Conference on Biometrics (IJCB). IEEE, 2021: 1-8.
- [26] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV). 2018:3-19.
- [27] LUO Z, LI J, ZHU Y. A deep feature fusion network based on multiple attention mechanisms for joint iris-periocular biometric recognition [J]. IEEE Signal Processing Letters, 2021, 28: 1060-1064.
- [28] YANG K, XU Z, FEI J. Dualsanet: Dual spatial attention network for iris recognition [C] // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 889-897.
- [29] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017: 6000-60108.
- [30] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [31] SHI W, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.
- [32] ZHAO Y, PO L M, YAN Q, et al. Hierarchical regression network for spectral reconstruction from RGB images [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020:422-423.
- [33] CHEN H, HU G, LEI Z, et al. Attention-based two-stream convolutional networks for face spoofing detection [J]. IEEE Transactions on Information Forensics and Security, 2019, 15: 578-593.
- [34] DENG J, GUO J, XUE N, et al. Arcface: Additive angular margin loss for deep face recognition [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019:4690-469.



**KONG Jialin**, born in 2000, master candidate, is a member of CCF (No. R3399G). Her main research interests include artificial intelligence and biometrics, etc.



**ZHANG Qi**, born in 1988, Ph.D, associate professor. Her main research interests include biometrics, machine learning, etc.

(责任编辑:喻黎)