

基于迁移学习的糖尿病视网膜病变辅助诊断算法

黄义劲¹ 吕俊延¹ 李萌² 夏鸿慧³ 袁进² 唐晓颖¹

¹南方科技大学电子与电气工程系,深圳 518055;²中山大学中山眼科中心 眼科学国家重点实验室,广州 510060;³广东省肇庆市高要区人民医院眼科 526040

通信作者:唐晓颖,Email:tangxy@sustech.edu.cn

【摘要】 目的 研究基于迁移学习的糖尿病视网膜病变(DR)诊断算法在小样本训练数据集中的应用。方法 采用广东省肇庆市高要区人民医院拍摄的4 465幅彩色眼底照片作为完整数据集。使用固定预训练参数和微调预训练参数的模型训练策略作为迁移学习组,将其与非迁移学习的随机初始化参数的策略对比,并将这3种策略应用在ResNet50、Inception V3和NASNet 3种深度学习网络的训练上。此外,从完整数据集中随机划分出小样本数据集,研究训练数据的减少对不同训练策略的影响。采用诊断模型的准确率和训练时间分析不同训练策略的效果。结果 取不同网络架构中的最优结果。微调预训练参数策略取得的模型准确率为90.9%,高于固定预训练参数策略的88.1%及随机初始化参数策略的88.4%。固定预训练参数策略的训练所需时间为10 min,少于微调预训练参数策略的16 h及随机初始化参数策略的24 h。在训练数据减少后,随机初始化参数策略得到的模型准确率平均下降8.6%,而迁移学习组准确率平均下降2.5%。结论 结合迁移学习中的微调策略和NASNet架构的新型识别算法在小样本数据集下仍保持高准确率,具有高度的鲁棒性,可用于DR的有效筛查。

【关键词】 糖尿病视网膜病变; 迁移学习; NASNet; 医疗图像分类; 人工智能

基金项目: 国家重点研发计划项目(2017YFC0112404); 南方科技大学2019年度大学生“大创”项目(2019G04)

DOI:10.3760/cma.j.issn.2095-0160.2019.08.003

Diabetic retinopathy detection algorithm based on transfer learning

Huang Yijin¹, Lyu Junyan¹, Li Meng², Xia Honghui³, Yuan Jin², Tang Xiaoying¹

¹Department of Electrical and Electronic Engineering, Southern University of Science and Technology, Shenzhen 518055, China; ²Zhongshan Ophthalmic Centre, Sun Yat-sen University, State Key Laboratory of Ophthalmology, Guangzhou 510060, China; ³Department of Ophthalmology, Gaoyao People's Hospital, Zhaoqing 526040, China

Corresponding author: Tang Xiaoying, Email: tangxy@sustech.edu.cn

【Abstract】 Objective To investigate a diabetic retinopathy (DR) detection algorithm based on transfer learning in small sample dataset. **Methods** Total of 4 465 fundus color photographs taken by Gaoyao People's Hospital was used as the full dataset. The model training strategies using fixed pre-trained parameters and fine-tuning pre-trained parameters were used as the transfer learning group to compare with the non-transfer learning strategy that randomly initializes parameters. These three training strategies were applied to the training of three deep learning networks: ResNet50, Inception V3 and NASNet. In addition, a small dataset randomly extracted from the full dataset was used to study the impact of the reduction of training data on different strategies. The accuracy and training time of the diagnostic model were used to analyze the performance of different training strategies. **Results** The best results in different network architectures were chosen. The accuracy of the model obtained by fine-tuning pre-training parameters strategy was 90.9%, which was higher than the strategy of fixed pre-training parameters (88.1%) and the strategy of randomly initializing parameters (88.4%). The training time for fixed pre-training parameters was 10 minutes, less than the strategy of fine-tuning pre-training parameters (16 hours) and the strategy of randomly initializing parameters (24 hours). After the training data was reduced, the accuracy of the model obtained by the strategy of randomly initializing parameters decreased by 8.6% on average, while the accuracy of the transfer learning group decreased by 2.5% on average. **Conclusions** The proposed automated and novel DR detection algorithm based on fine-tune and NASNet structure maintains high accuracy in small sample dataset, is found to be robust, and effective for the preliminary diagnosis of DR.

【Key words】 Diabetic retinopathy; Transfer learning; NASNet; Medical image classification; Artificial intelligence

Fund program: National Key R&D Program of China (2017YFC0112404); College Students' Innovative Entrepreneurial Training Plan Program 2019 of SUSTech (2019G04)

DOI:10.3760/cma.j.issn.2095-0160.2019.08.003

糖尿病视网膜病变(diabetic retinopathy, DR)是糖尿病的严重并发症之一,是一种主要的致盲疾病^[1]。DR 的检测和评估方法主要是基于彩色眼底照片的解读,但 DR 早期发病隐匿,病变的诊断对医师的能力要求较高且工作量大,加之眼科医疗资源分布不均,导致基层的 DR 患者无法获得及时的诊断,进而延误治疗^[2]。近期,随着卷积神经网络(convolution neural network, CNN)和人工智能(artificial intelligence, AI)技术的发展,基于 CNN 的分类算法逐渐被应用于基于彩色眼底照片的 DR 早期筛查。有研究使用超过 7 万张公开 EyePACS 彩色眼底照片数据库^[3]来训练特殊设计的 13 层 CNN,最终得到 75% 的诊断准确率^[4]。另有研究也使用 EyePACS 数据集来训练深度残差网络,基于 5-折交叉验证得到 94.0% 的敏感度和 98.0% 的特异性^[5]。然而,大多数已有的深度学习方案都不可避免地需要海量的标注数据来训练模型。与此同时, EyePACS 数据集等大型公开数据集的标注与国内的眼底图像分级标准存在差异^[6]。根据指定标准收集并标注大量的眼底照片十分困难且耗时,因此在有限数据集下得到高准确率模型的深度学习算法十分必要。本研究中提出基于迁移学习^[7]的 NASNet^[8]结构的 DR 诊断算法,并以 4 465 张彩色眼底照片的数据集来量化其准确率及优化特性。

1 数据集与方法

1.1 数据集来源

本研究中使用的眼底照片数据集来自广东省肇庆市高要区人民医院,图像由 TOPCON-50DX 的台式眼底照相机拍摄,保存为 2 880×2 136 分辨率、JPG 格式的 RGB 彩色图像。数据集由中山大学中山眼科中心 2 名经验丰富的眼科医师交叉阅片判断并标注,意见不一致时由第 3 名医师判定。数据集共有 4 465 幅,其中为 DR 的眼底照片 1 955 幅,正常眼底照片 2 510 幅。

1.2 方法

1.2.1 数据预处理 图片的预处理主要包括数据增强和标准化。(1)数据增强 由于数据数量有限,容易产生过拟合问题^[9],且患病与健康的样本数量不平衡,为避免样本偏移,同时使训练得到的模型有更强的鲁棒性,对训练数据集进行扩增。本研究中通过对彩色眼底照片进行水平、垂直翻转及两者组合等方法生成新样本(图 1)。(2)数据归一化 RGB 眼底照片的各个特征是由多个范围在 [0, 255] 的像素值组成,数值之间差异波动较大,会导致它们对模型的影响程度不同。标准化是指利用线性变换将各个特征缩放到相

同尺度,使数据较为稳定并可以加速优化过程。因该研究采用了迁移学习算法,故采用的预处理方法与预训练模型时所使用的方法保持一致:(1) Inception V3 和 NASNet 采用标准化方法,将图片中的像素值均缩放到 [-1, 1],如下式所示: $I_o = (I_i - 127.5) / 127.5$,其中, I_i 为输入的原图片, I_o 为输出的标准化后的图片;(2) ResNet50 采用 0 中心化方法,分别将图片的各个色彩通道减去 ImageNet^[10] 训练数据集对应通道的均值,如下式所示: $I_{or} = I_{ir} - 123.68$; $I_{og} = I_{ig} - 116.78$; $I_{ob} = I_{ib} - 103.94$,其中, I_{ir} 、 I_{ig} 、 I_{ib} 为输入的原图片 RGB 色彩三通道, I_{or} 、 I_{og} 、 I_{ob} 为输出的标准化后的图片 RGB 色彩三通道。

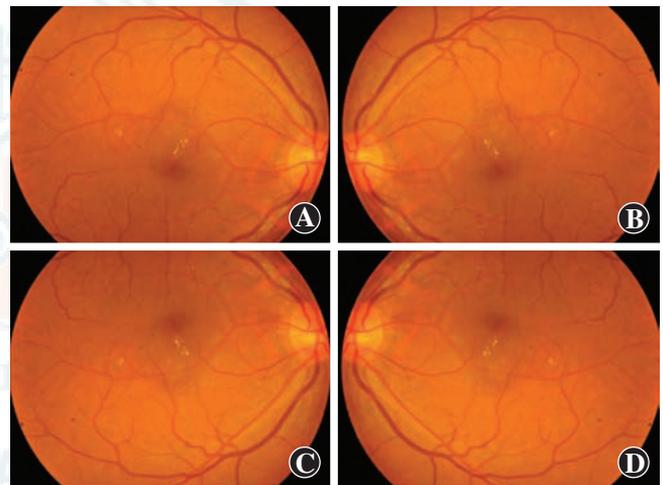


图 1 数据增强示意图 通过对眼底照片进行水平、垂直翻转及两者组合可以获得数据增强图 A:原图 B:水平翻转图 C:垂直翻转图 D:水平翻转和垂直翻转组合图

1.2.2 数据划分 本实验将数据划分成训练集、测试集和验证集。首先,将 DR 样本按 7:2:1 的比例随机划分,再从正常人样本中划分出与 DR 类别同等数量的测试集与验证集。然后,通过数据增强将两类样本的训练集扩增至 4 倍,接着对正常人训练集进行随机采样,平衡训练样本数量。此外,从两类原始数据集的训练集中各随机采样 500 幅,进行相同的数据增强操作,作为小样本数据集。最终数据划分如表 1 所示。

表 1 数据划分

类别		数据增强前			数据增强后		
		训练	测试	验证	训练	测试	验证
总样本	DR	1 372	391	198	5 488	391	198
	正常	1 927	391	198	5 488	391	198
小样本	DR	500	391	198	2 000	391	198
	正常	500	391	198	2 000	391	198

注:DR:糖尿病视网膜病变

1.2.3 模型训练 采用迁移学习,一种通过对已经学习了其他相关任务的网络转移知识来改进新任务中的学习策略(图 2)。具体的迁移学习应用方式有多种,本研究中采用 2 种典型的方法:第 1 种训练过程中载入在其他大型数据集上训练后得到的网络参数,并固定参数,仅通过反向传播来重新训练新的分类器参数(以下简称固定方案);第 2 种为微调(fine-tune)策略,同样载入预训练参数,但不固定其参数,通过反向传播更新全部可训练参数(以下简称微调方案)。

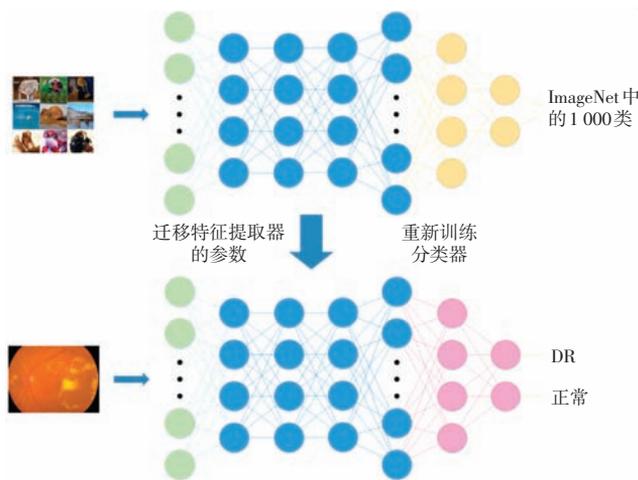


图 2 迁移学习中固定特征提取器参数的策略 注:DR:糖尿病视网膜病变

为了比较不同训练策略和模型架构在不同样本数量数据集下的效果,分组进行实验。在 ResNet50、Inception V3 和 NASNet 网络架构下(表 2),结合 3 种不同的训练策略:第 1 种根据网络设计的方式随机初始化全部参数(以下简称随机初始化方案);第 2 种和第 3 种则为前述的两类迁移学习方法,载入的参数为 ImageNet 上预训练的参数。最后使用以上的方法在完整数据集和小样本数据集上分别进行实验。

将数据集进行数据增强和数据划分后,实验训练过程如下:(1)若采用迁移学习的策略,则在图像输入前,进行与所载入参数模型对应的标准化操作。作为比较,非迁移学习的实验组也采用相同的标准化操作。最后,将输入压缩成各种网络对应的输入大小(表 2)。(2)网络参数的初始化:①非迁移学习组随机初始化网络参数;②迁移学习组中,结合微调预训练参数策略的网络载入在 ImageNet 数据集上预训练得到的网络参数;③结合固定预训练参数策略的网络则在前者的基础上裁剪去瓶颈层后的部分,剩余部分作为特征提取层,接入新的适用于当前任务的全连接层作为分类层。实验设计分类器为两层,各方法中的隐层大小统

一为 1 024,各网络架构输出的特征向量大小如表 2。(3)采用 Adam 优化算法,根据不同网络,调整至合适的学习率。非迁移学习方案下的学习率为 0.000 1,而迁移学习允许训练中使用更高的学习率而不会导致无法收敛,因此迁移学习方案学习率设为 0.001。(4)设置参数随机初始化的模型共训练 500 个 epoch。考虑到显卡内存的限制,每批样本图像为 32 幅。使用迁移学习的模型训练总共迭代 4 000 批,每批样本图像为 256 幅。(5)结合固定预训练参数策略的网络固定住特征提取部分的参数,不断迭代并更新分类层的参数。结合微调预训练参数策略的网络和非迁移学习方案的网络在迭代中更新全部的可训练参数。两者均保存验证集准确率最高的模型,直至达到最大迭代次数。(6)训练结束后,将保存的模型应用于测试集上并计算准确率,作为最后效果比较的评估指数。

表 2 所测评网络基础信息

网络架构	参数量	输入大小	瓶颈层特征向量大小
ResNet50	25 636 712	224×224×3	2 048
Inception V3	23 851 784	299×299×3	2 048
NASNet	88 949 818	331×331×3	4 032

本实验使用的图像处理工具是 OpenCV,深度学习框架是 Tensorflow,其支持图形处理器(graphics processing unit,GPU)运算。用于训练的 GPU 为显卡内存 12 G 的 NVIDIA TITAN XP。

2 结果

准确率及训练时间取重复实验的平均数据见表 3,其中训练时间是指在验证集上得到准确率最高的模型所使用的时间。

在 3 种不同的训练策略下,固定方案所使用的训练时间最少,平均仅为 7.6 min,微调方案居中,平均为 229 min,而随机初始化方案训练时间最长,平均为 423 min。

使用完整数据集训练,相同的 CNN 架构下,除了 NASNet,随机初始化方案的准确率均高于固定方案。但是当使用小样本数据集训练,随机初始化方案的准确率平均下降 8.6%,固定方案平均下降 3.8%,而微调方案平均仅下降 1.2%。可见,随机初始化方案的准确率严重下降,最终固定方案的准确率均与随机初始化方案相当或优于随机初始化方案。微调方案的准确率和训练时间均优于随机初始化方案,并且准确率在 2 种数据集下均优于其他所有方案,在小样本数据集中的优势更加明显。模型识别率方面,在 ResNet50、Inception

V3 和 NASNet 3 种结合微调策略的方案中, NASNet 准确率最高, 训练时间也最长, 不过相较于 NASNet 的随机初始化方案, 微调方案使 NASNet 准确率平均提升 4.45%, 同时较大程度地减少了训练时间。

在完整数据集下, 使用固定预训练参数策略训练 NASNet 的过程中, 对每步的交叉熵和验证集准确率进行记录, 并使用 Tensorboard 生成变化曲线。从图中可以看出, 验证集准确率提升十分迅速, 在约 100 步便达到 90%, 模型也在短时间内收敛, 约 1 700 步后趋于平稳(图 3)。

表 3 不同方案分类结果比较

训练策略	CNN	完整数据集		小样本数据集	
		准确率 (%)	训练时间 (min)	准确率 (%)	训练时间 (min)
随机初始化参数 (非迁移学习)	ResNet50	84.4	105	73.7	40
	InceptionV3	88.4	208	76.9	63
	NASNet	87.7	1 488	84.0	635
固定预训练参数 (迁移学习)	ResNet50	82.5	5	79.7	2
	InceptionV3	86.1	6	81.7	0.5
	NASNet	88.1	10	83.9	22
微调预训练参数 (迁移学习)	ResNet50	90.4	70	89.0	7
	InceptionV3	90.0	218	89.0	54
	NASNet	90.9	1 009	89.7	105

注: CNN: 卷积神经网络

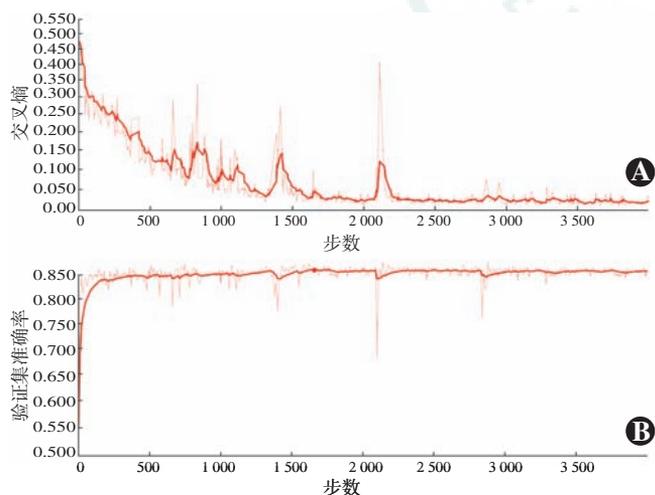


图 3 固定预训练参数的 NASNet 训练过程中的变化曲线 A: 损失函数交叉熵, 该方案的训练在约 1 700 步收敛 B: 在 198 幅验证集上的准确率, 约 100 步后达 90%

3 讨论

CNN 往往需要通过对大量数据进行训练, 来调整网络中的参数, 从而得到一个鲁棒性强的有效分类器。然而, 但相比于大部分计算机视觉领域的模式识别任务, 医疗图像领域的分类任务往往会因为标注难度大

而面临可用的训练数据有限的问题^[11]。在实验中, 当使用小样本数据集训练, 随机初始化参数的方案由于训练数据量不足, 难以调整网络架构中巨量参数, 训练产生过拟合, 准确率严重下降。本研究中采用迁移学习的训练策略来解决该问题, 并通过实验证明了在样本数量不充足的情况下, 使用迁移学习能在提升准确率的同时减少模型训练的时间。迁移学习利用了深度神经网络中不同位置具有不同功能的特点, 即预训练模型经过大量不同类别的数据训练后, 位于低层的网络提取出的信息为图像的通用信息, 如形状、边缘、颜色等, 而高层网络则通过这些信息来进行分类^[12], 因此低层的特征提取器可简单地迁移到其他领域, 而新模型仅需重新训练高层网络来适应新领域的分类。在本研究中, NASNet 网络架构的采用与迁移学习相得益彰。NASNet 在提升特征提取能力的同时不可避免地增加大量参数, 导致模型的训练对数据量和计算能力要求提高, 而迁移学习恰好可以弥补这个缺陷, 固定特征提取器参数可以极大程度地减少训练参数, 微调预训练参数可以使模型训练起点更高, 更容易到达最优解。虽说迁移学习可以较大程度地减少模型训练对数据量的依赖, 但在许多特定的任务下, 获取充足的高质量数据仍是成功的关键。

迁移学习是一种思想, 其应用的方式不限于本研究所实现的方案。例如, 可固定特征提取器中部分卷积层, 微调其余几层。对于不同的任务, 最佳的迁移学习方案也不同, 需经过大量实验尝试。

训练数据过少在深度学习领域是十分常见的问题, 尤其是医疗图像识别领域。本研究所提出的使用 NASNet 等深层网络结合迁移学习的方案不仅对 DR 的辅助诊断任务有效, 还适用于其他多种训练数据有限的情形, 如 Hnyuh 等^[13]在肿瘤分类的任务上采用迁移学习, 在 607 张乳房 X 射线照片数据集上曲线下面积达到了 86%。此外, Burlina 等^[14]将迁移学习应用在年龄相关性黄斑变性的分类上, 使用 5 664 张彩色眼底照片数据集, 准确率达 93.4%。以上实验表明迁移学习能够加快收敛速度, 提升模型在小样本数据集上的表现。应用基于该方案的 DR 诊断模型可有效辅助临床医生进行 DR 筛查, 减少医生的工作量, 降低 DR 的误诊率。随着更多高准确率、高性能深度算法的提出, AI 辅助诊断模式将成为今后发展的趋势^[15]。

综上所述, 本研究结果显示结合迁移学习中的微调策略和 NASNet 架构的新型识别算法在小样本数据集下仍保持高准确率, 具有高度的鲁棒性, 可用于 DR 的有效筛查。

利益冲突 所有作者均声明不存在利益冲突

参考文献

- [1] 许迅. 我国眼底病研究发展现状、进展和努力方向[J]. 中华眼科杂志, 2014, 50(11): 801-803. DOI: 10. 3760/cma. j. issn. 0412-4081. 2014. 11. 001.
Xu X. Ocular fundus disease in China: the current situation, progression, and issues to be resolved[J]. Chin J Ophthalmol, 2014, 50(11): 801-803. DOI: 10. 3760/cma. j. issn. 0412-4081. 2014. 11. 001.
- [2] 邹海东, 何明光. 积极开展社区糖尿病视网膜病变筛查和早期干预工作[J]. 中华眼科杂志, 2016, 52(11): 801-804. DOI: 10. 3760/cma. j. issn. 0412-4081. 2016. 11. 001.
Zou HD, He MG. Active screening and early intervention of diabetic retinopathy in community service[J]. Chin J Ophthalmol, 2016, 52(11): 801-804. DOI: 10. 3760/cma. j. issn. 0412-4081. 2016. 11. 001.
- [3] Cuadros J, Bresnick G. EyePACS: an adaptable telemedicine system for diabetic retinopathy screening[J]. J Diabetes Sci Technol, 2009, 3(3): 509-516. DOI: 10. 1177/193229680900300315.
- [4] Pratt H, Coenen F, Broadbent DM, et al. Convolutional neural networks for diabetic retinopathy[J]. Proc Comput Sci, 2016, 90: 200-205.
- [5] Gargeya R, Leng T. Automated identification of diabetic retinopathy using deep learning[J]. Ophthalmology, 2017, 124(7): 962-969. DOI: 10. 1016/j. ophtha. 2017. 02. 008.
- [6] 中华医学会眼科学分会眼底病学组, 中国医师协会眼科医师分会眼底病专业委员会. 我国糖尿病视网膜病变筛查的图像采集及阅片指南(2017年)[J]. 中华眼科杂志, 2017, 53(12): 890-896. DOI: 10. 3760/cma. j. issn. 0412-4081. 2017. 12. 003.
- [7] Pan SJ, Yang Q. A survey on transfer learning[J]. IEEE Transact Knowledge Data Engineer, 2010, 22(10): 1345-1359. DOI: 10. 1109/TKDE. 2009. 191.
- [8] Elsken T, Metzen JH, Hutter F. Neural architecture search: a survey[J]. J Machin Learning Res, 2019, 20(55): 1-21.
- [9] Hawkins DM. The problem of overfitting[J]. J Chem Inf Comput Sci, 2004, 44(1): 1-12. DOI: 10. 1021/ci0342472.
- [10] Russakovsky O, Deng J, Su H, et al. ImageNet large scale visual recognition challenge[J]. Int J Comput Vis, 2015, 115(3): 211-252.
- [11] Kermany DS, Goldbaum M, Cai W, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning[J]. Cell, 2018, 172(5): 1122-1131. DOI: 10. 1016/j. cell. 2018. 02. 010.
- [12] Shin HC, Roth HR, Gao M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. IEEE Trans Med Imaging, 2016, 35(5): 1285-1298. DOI: 10. 1109/TMI. 2016. 2528162.
- [13] Huynh BQ, Li H, Giger ML. Digital mammographic tumor classification using transfer learning from deep convolutional neural networks[J/OL]. J Med Imaging (Bellingham), 2016, 3(3): 034501 [2019-01-20]. https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4992049/. DOI: 10. 1117/1. JMI. 3. 3. 034501.
- [14] Burlina P, Pacheco KD, Joshi N, et al. Comparing humans and deep learning performance for grading AMD: a study in using universal deep features and transfer learning for automated AMD analysis[J]. Comput Biol Med, 2017, 82: 80-86. DOI: 10. 1016/j. compbiomed. 2017. 01. 018.
- [15] 林浩添, 吴晓航. 加快基于眼科图像数据库的眼病人工智能辅助诊断平台建设[J]. 中华实验眼科杂志, 2018, 36(8): 577-580. DOI: 10. 3760/cma. j. issn. 2095-0160. 2018. 08. 001.
Lin HT, Wu XH. Accelerating the construction of artificial intelligence diagnostic platform based on ophthalmic imaging database[J]. Chin J Exp Ophthalmol, 2018, 36(8): 577-580. DOI: 10. 3760/cma. j. issn. 2095-0160. 2018. 08. 001.

(收稿日期: 2019-02-25 修回日期: 2019-06-30)

(本文编辑: 刘艳)

读者·作者·编者

本刊对基金项目的证明和著录要求

文稿所涉及的课题如为国家级、部级、省级等基金资助项目, 请分别用中英文表述并分别列于文章中中英文摘要关键词之下, “基金项目:”进行标识, 并注明基金项目名称, 并在圆括号内注明基金项目编号。基金项目名称应按国家有关部门规定的正式名称填写, 多个基金资助的项目请全部列出, 按资助机构的等级顺序排列, 并以“;”隔开。如: 基金项目: 国家自然科学基金项目(30271269); 国家重点基础研究发展规划(973计划)(2013CB532002); Fund program: National Natural Science Foundation of China(30271269); National Key Basic Research Program of China(973 Program)(2013CB532002)。获得基金项目资助的论文投稿时请提供基金项目资助证明的复印件或扫描后发至编辑部信箱。

本刊稿件处理流程

本刊实行以同行审稿为基础的三级审理制度(编辑初审、专家外审、编委会终审)稿件评审。编辑部在稿件审理过程中坚持客观、公平、公正的原则, 郑重承诺审稿过程中尊重和保护审稿专家、作者及稿件的私密权。专家审理认为不宜刊用的稿件, 编辑部将告知作者专家的审理意见, 对稿件处理有不同看法的作者有权向编辑部申请复议, 但请写出申请理由和意见。

稿件审理过程中作者可通过“中华医学会杂志社远程稿件管理系统”查询稿件的审理结果。作者如需要采用通知或退稿通知可与编辑部联系。编辑部发给作者修改再审稿的稿件, 如2个月没有修回, 视为作者自行撤稿。编辑部的各种通知将通过Email发出, 投稿后和稿件审理期间请作者留意自己的电子信箱。作者自收到采用通知之日起, 即视为双方建立合约关系, 作者如撤稿必须向编辑部申诉理由并征得编辑部同意。一旦稿件进入编排阶段, 作者不应提出自撤稿件, 在此期间因一稿两投或强行撤稿而给本刊造成不良影响和/或经济损失者, 编辑部有权给以公开曝光、通报并实施经济赔偿, 作者自行承担一切责任和后果。

根据《中华人民共和国著作权法》的相关条文, 本刊编辑可对待发表的来稿按照编辑规范和专业知进行文字加工、修改和删减, 修改后的稿件作者须认真校对核实, 修改涉及文章的核心内容时双方应进行沟通并征得作者同意。除了编辑方面的技术加工以外, 作者对已经发表论文的全部内容文责自负。稿件编辑流程中编辑退回作者修改的稿件逾期2个月不修回者, 视作自行撤稿。

(本刊编辑部)